

**UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**TRANSFORMADA WAVELET E  
REDES NEURAIS ARTIFICIAIS NA ANÁLISE DE  
SINAIS RELACIONADOS À QUALIDADE DA  
ENERGIA ELÉTRICA**

**DISSERTAÇÃO DE MESTRADO**

**Giovani Guarienti Pozzebon**

**Santa Maria, RS, Brasil**

**2009**

**TRANSFORMADA WAVELET E REDES NEURAIAS  
ARTIFICIAIS NA ANÁLISE DE SINAIS RELACIONADOS À  
QUALIDADE DA ENERGIA ELÉTRICA**

**por**

**Giovani Guarienti Pozzebon**

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Processamento de Energia, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia Elétrica.**

**Orientador (a): Profa. Dra. Luciane Neves Canha**

**Co-Orientador: Prof. Dr. Natanael Rodrigues Gomes**

**Santa Maria, RS, Brasil**

**2009**

**Universidade Federal de Santa Maria  
Centro de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica**

A Comissão Examinadora, abaixo assinada,  
aprova a Dissertação de Mestrado

**TRANSFORMADA WAVELET E REDES NEURAIAS  
ARTIFICIAIS NA ANÁLISE DE SINAIS RELACIONADOS À  
QUALIDADE DA ENERGIA ELÉTRICA**

elaborada por  
**Giovani Guarienti Pozzebon**

como requisito parcial para obtenção do grau de  
**Mestre em Engenharia Elétrica**

**COMISSÃO EXAMINADORA:**

---

**Luciane Neves Canha, Dra. (UFSM)**  
(Presidente/Orientadora)

---

**André Augusto Ferreira, Dr. (UNIPAMPA)**

---

**Felix Alberto Farret, Ph. D. (UFSM)**

Santa Maria, 10 de fevereiro de 2009.

*Aos meus queridos pais  
Esilda Pozzebon e Itamar  
Pozzebon (in memoriam)*

*Aos meus irmãos Jocelito e  
André Marcos e também  
aos meus sobrinhos*

*À minha amada noiva e  
companheira Keity Taminski*

## **AGRADECIMENTOS**

Em primeiro lugar, eu gostaria de agradecer a Deus por me dar saúde, paz, tranqüilidade e também me iluminar e estar presente em todos os momentos de minha vida.

Gostaria de agradecer à minha mãe Esilda e aos meus irmãos Jocelito e André pelo amor, apoio e compreensão que eles dedicaram em todos os momentos dos meus estudos e principalmente durante o meu curso de mestrado e pelos ensinamentos passados ao longo da vida. Também gostaria de agradecer muito ao meu pai Itemar, que não se encontra mais entre Nós, por sempre me apoiar e me inspirar a seguir em frente da melhor maneira possível.

Um agradecimento muito especial a minha noiva e companheira Keity, que divide comigo os bons e maus momentos, por ela sempre me passar o seu amor e carinho, vibrar em todas nossas conquistas e também pela sua compreensão nos momentos de renúncia.

Gostaria de agradecer à professora Luciane Canha pela oportunidade concedida e por sempre disponibilizar a sua atenção e apoio durante a realização deste trabalho. Aos colegas do CEEMA pelas conversas e companheirismo.

Aos professores Ricardo Quadros e Natanael Gomes pelas suas colaborações e horas de dedicação ao trabalho e também pelos seus conselhos e ensinamentos que sempre me motivaram e proporcionaram oportunidades indiscutíveis. Agradeço também aos professores André Ferreira e Felix Farret que colaboraram e fizeram parte da comissão examinadora.

À Universidade Federal de Santa Maria, ao Programa de Pós-Graduação em Engenharia Elétrica e principalmente ao apoio financeiro concedido pela CAPES e CEEMA.

## RESUMO

Dissertação de Mestrado  
Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal de Santa Maria

### **TRANSFORMADA WAVELET E REDES NEURAIAS ARTIFICIAIS NA ANÁLISE DE SINAIS RELACIONADOS À QUALIDADE DA ENERGIA ELÉTRICA**

AUTOR: GIOVANI GUARIENTI POZZEBON

ORIENTADORA: LUCIANE NEVES CANHA

CO-ORIENTADOR: NATANAEL RODRIGUES GOMES

Data e Local da Defesa: Santa Maria, 10 de fevereiro de 2009.

Este trabalho apresenta um diferente método para a classificação de distúrbios em sinais elétricos visando analisar a qualidade da energia elétrica (QEE). Para isso, a análise de componentes principais (ACP) e a transformada *wavelet* (TW) são associadas. O desvio padrão dos coeficientes de detalhes e a média dos coeficientes de aproximação da TW são combinados para extrair características discriminantes dos distúrbios. A ACP é utilizada para condensar a informação dessas características, originando um conjunto menor de características descorrelacionadas. Estas são processadas por uma rede neural probabilística (RNP) para realizar as classificações. Na aplicação do algoritmo, inicialmente, foram utilizadas senóides puras e seis classes de sinais que representam os diferentes tipos de distúrbios: afundamentos e interrupções de tensão, *flicker*, transitórios oscilatórios, distorções harmônicas e *notching*. Em seguida, são acrescentadas mais quatro situações ocorridas em sistemas de geração distribuída (GD) conectados em redes de distribuição através de conversores. São elas: conexão da geração distribuída, conexão de carga local, operação normal e ocorrência de ilhamento. Neste caso, os sinais de tensão no ponto de acoplamento comum (PAC) entre a GD e a rede são medidos e analisados pelo algoritmo. Em ambos os casos, os sinais são decompostos em nove níveis de resolução pela transformada *wavelet*, ficando representados por coeficientes de detalhes e aproximações. A aplicação da transformada *wavelet* discreta gera muitas variações nos coeficientes. Por isso a aplicação do desvio padrão, nos diferentes níveis de resolução, é capaz de quantificar a magnitude destas variações. Para considerar as características originadas pelas componentes de baixa frequência contidas nos sinais, propõe-se o uso da média dos coeficientes de aproximação do sinal. Os desvios padrões dos coeficientes de detalhes e a média da aproximação compõem um vetor de características contendo 10 variáveis para cada sinal analisado. Antes de realizar a classificação estes vetores passam por um algoritmo de análise das componentes principais, visando reduzir a dimensão dos vetores de características que continham variáveis correlacionadas e conseqüentemente, reduzir o tempo de processamento da rede neural. As componentes principais, descorrelacionadas, são ordenadas de forma que as primeiras componentes contenham a maior parte das informações das variáveis originais. Dessa forma, as três primeiras componentes são escolhidas, pois elas representam cerca de 90% das informações relacionadas com o sinal em estudo. Assim, um novo conjunto de variáveis é gerado através das componentes principais, reduzindo o número de variáveis contidas no vetor de características de 10 (dez) para 3 (três). Finalmente, estas 3 variáveis são inseridas em uma rede neural para a classificação dos distúrbios de forma que o resultado da rede neural indica o tipo de distúrbio presente no sinal analisado.

Palavras-chave: análise de componentes principais; geração distribuída; qualidade da energia elétrica; redes neurais e transformada wavelet.

## **ABSTRACT**

Master Thesis

Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal de Santa Maria

### **WAVELET TRANSFORM AND ARTIFICIAL NEURAL NETWORKS IN POWER QUALITY SIGNAL ANALYSIS**

**AUTHOR: GIOVANI GUARIENTI POZZEBON**

**RESEARCH SUPERVISOR: LUCIANE NEVES CANHA**

**CO-RESEARCH SUPERVISOR: NATANAEL RODRIGUES GOMES**

**Place and Date of Examination: Santa Maria, 10<sup>th</sup> February, 2009.**

This work presents a different method for power quality signal classification using the principal components analysis (PCA) associated to the wavelet transform (WT). The standard deviation of the detail coefficients and the average of the approximation coefficients from WT are combined to extract discriminated characteristics from the disturbances. The PCA was used to condense the information of those characteristics, than a smaller group of characteristics uncorrelated were generated. These were processed by a probabilistic neural network (PNN) to accomplish the classifications. In the application of the algorithm, in the first case, seven classes of signals which represent different types of disturbances were classified, they are as follows: voltage sag and interruption, flicker, oscillatory transients, harmonic distortions, notching and normal sine waveform. In the second case were increased four more situations that usually happen in distributed generation systems connected to distribution grids through converters, they are as follows: connection of the distributed generation, connection of local load, normal operation and islanding occurrence. In this case, the voltage on the point of common coupling between GD and grid were measured by simulations and were analyzed by the proposed algorithm. In both cases, the signals were decomposed in nine resolution levels by the wavelet transformed, being represented by detail and approximation coefficients. The application of the WT generated a lot of variations in the coefficients. Therefore, the application of the standard deviation in different resolution levels can quantify the magnitude of the variations. In order to take into account those features originated from low frequency components contained in the signals, was proposed to calculate the average of the approximation coefficients. The standard deviations of the detail coefficients and the average of the approximation coefficients composed the feature vector containing 10 variables for each signal. Before accomplishing the classification these vectors were processed by the principal component analysis algorithm in order to reduce the dimension of the feature vectors that contained correlated variables. Consequently, the processing time of the neural network were reduced to. The principal components, which are uncorrelated, were ordered so that the first few components account for the most variation that all the original variables acted previously. The first three components were chosen. Like this, a new group of variables was generated through the principal components. Thus, the number of variables on the feature vector was reduced to 3 variables. These 3 variables were inserted in a neural network for the classification of the disturbances. The output of the neural network indicates the type of disturbance.

Keywords: distributed generation; neural networks; power quality; principal component analysis; wavelet transform.

## LISTA DE FIGURAS

Figura 2.1 – Corrente transitória impulsiva causada por uma descarga atmosférica (IEEE Std 1159, 1995).....	26
Figura 2.2 – Corrente transitória oscilatória causada pelo chaveamento de capacitores <i>back-to-back</i> (IEEE Std 1159, 1995).....	27
Figura 2.3 – Transitório oscilatório de baixa frequência causado pela energização de banco de capacitores (IEEE Std 1159, 1995).....	28
Figura 2.4 – Interrupção momentânea devido a um curto-circuito e subsequente religamento (IEEE Std 1159, 1995). ....	31
Figura 2.5 – Afundamento de tensão causado por uma falta fase-terra (IEEE Std 1159, 1995). ....	32
Figura 2.6 – Afundamento de tensão temporário causado pela partida de um motor de indução (IEEE Std 1159, 1995). ....	33
Figura 2.7 – Elevação de tensão devido a uma falta fase-terra (IEEE Std 1159, 1995).....	34
Figura 2.8 – Tolerâncias típicas de tensão para computadores (curva CBEMA).....	35
Figura 2.9 – Vida útil de um transformador em função da distorção harmônica de corrente. ....	38
Figura 2.10 – Vida útil <i>versus</i> sobre-temperatura em capacitores. ....	40
Figura 2.11 – Exemplo de <i>notching</i> na tensão causado por um conversor trifásico. ....	42
Figura 2.12 – Oscilações de tensão oriundas da operação de um laminador (OLESKOVICZ, 2004).....	43
Figura 3.2 – Representação de um sinal em diferentes escalas e posições. ....	48
Figura 3.3 – Demonstração do fator de escala em uma função senóide.....	48
Figura 3.4 – Demonstração do fator de escala atuando em uma função wavelet.....	49
Figura 3.5 – Translação de uma função <i>wavelet</i> : (a) Função <i>wavelet</i> $\psi(t)$ ; (b) Função <i>wavelet</i> transladada $\psi(t - k)$ . ....	49
Figura 3.6 – Grade de amostragem diádica ( $2^{-m}$ ) para a transformada <i>wavelet</i> discreta. ....	51
Figura 3.7 – Filtragem de um sinal.....	55
Figura 3.8 – Decomposição de um sinal: (a) sem <i>downsampling</i> ; (b) com <i>downsampling</i> . ....	56
Figura 3.9 – Exemplo de filtragem com <i>downsampling</i> de um sinal senoidal ruidoso.....	57

Figura 3.10 – Ilustração do processo sucessivo de decomposição de um sinal em três níveis pela AMR. ....	57
Figura 3.11 – Reconstrução de um sinal filtrado.....	58
Figura 3.12 – processo de aumento do número de amostras de um sinal. ....	58
Figura 3.13 – Processo de decomposição e reconstrução de um sinal. ....	59
Figura 3.14 – Processo de reconstrução da aproximação $A_1$ alimentado com vetor de zeros..	59
Figura 3.15 – Reconstrução do primeiro nível de detalhe do sinal com inserção do vetor de zeros.....	60
Figura 3.16 – Diferentes formas para se reconstruir o sinal original a partir de seus coeficientes. ....	60
Figura 3.17 – Amplitude <i>versus</i> tempo da AMR de um sinal amostrado a 15360 Hz, com detalhamento das frequências.....	62
Figura 6.1 – Diagrama do algoritmo de classificação de distúrbios.....	81
Figura 6.2 – Ilustração da decomposição de $c_0(n)$ em duas escalas.....	82
Figura 6.3 – Decomposição de um sinal de tensão com afundamento e sem a presença de harmônicos. ....	83
Figura 6.4 – Decomposição de um sinal de tensão com afundamento e harmônicos. ....	84
Figura 6.5 – Sinal de tensão com transitório oscilatório. ....	84
Figura 6.6 – Curvas de desvios padrões obtidas da análise de um sinal de tensão com afundamento e de uma senóide pura.....	85
Figura 6.7 – Curvas de desvios padrões obtidas da análise de um sinal de tensão com transitório oscilatório e de uma senóide pura. ....	86
Figura 6.8 – Variância representada pelas 4 primeiras componentes principais.....	88
Figura 6.9 – Estrutura de uma Rede Neural Probabilística. ....	90
Figura 7.1 – Variância representada pelas componentes principais dos diferentes grupos.....	95
Figura 7.2 – Variâncias representadas pelas 4 primeiras componentes principais e variâncias acumuladas pelas 3 primeiras componentes em cada um dos grupos. ....	95
Figura 7.3 – Sistema de geração distribuída simulado no <i>software</i> PSCAD. ....	99
Figura 7.4 – Sinal de tensão e coeficientes de detalhes no momento da conexão da GD.....	101
Figura 7.5 – Sinal de tensão e coeficientes de detalhes no instante em que uma carga local foi conectada. ....	102
Figura 7.6 – Sinal de tensão e coeficientes de detalhes quando o sistema de GD e rede operam normalmente. ....	102
Figura 7.7 – Sinal de tensão e coeficientes de detalhes quando a GD começa a operar isolada da rede.....	103
Figura 7.8 – Variâncias representadas pelas componentes principais e variâncias acumuladas pelas 3 primeiras componentes em cada um dos grupos. ....	104

## LISTA DE TABELAS

Tabela 2.1 – Categorias e características típicas dos fenômenos eletromagnéticos típicos nos sistemas elétricos de potência (DUGAN et al., 2003).....	25
Tabela 6.1 – Relação entre as escalas e faixas de frequências. ....	83
Tabela 7.1 – Resultados das classificações sem a ACP e utilizando o grupo A para treinamento. ....	93
Tabela 7.2 – Resultados das classificações sem a ACP e utilizando o grupo B para treinamento. ....	94
Tabela 7.3 – Resultados das classificações sem a ACP e utilizando o grupo C para treinamento. ....	94
Tabela 7.4 – Resultados das classificações sem a ACP e utilizando o grupo D para treinamento. ....	94
Tabela 7.5 – Resultados das classificações com a ACP e utilizando o grupo A para treinamento. ....	96
Tabela 7.6 – Resultados das classificações com a ACP e utilizando o grupo B para treinamento. ....	96
Tabela 7.7 – Resultados das classificações com a ACP e utilizando o grupo C para treinamento. ....	97
Tabela 7.8 – Resultados das classificações com a ACP e utilizando o grupo D para treinamento. ....	97
Tabela 7.9 – Tempos e resoluções das classificações dos diferentes grupos. ....	98
Tabela 7.10 – Tempos de processamento para treinamento das redes neurais. ....	98
Tabela 7.11 – Resultados das classificações com a ACP utilizando o grupo A2 para treinamento. ....	104
Tabela 7.12 – Resultados das classificações com a ACP utilizando o grupo B2 para treinamento. ....	105
Tabela 7.13 – Resultados das classificações com a ACP utilizando o grupo C2 para treinamento. ....	105

## LISTA DE ABREVIATURAS E SIGLAS

ACP	Análise de Componentes Principais
AMR	Análise de Multirresolução
ANEEL	Agência Nacional de Energia Elétrica
ANN	<i>Analytical Neural Network</i>
ANSI	<i>American National Standards Institute</i>
ASD	<i>Adjustable Speed Driver</i>
CA	Corrente Alternada
CBEMA	<i>Computer Business Equipment Manufactures Association</i>
CC	Corrente Contínua
CCT	Capacitores Controlados por Tiristores
CIGRÉ	<i>International Council on Large Electric Systems</i>
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
DHT	Distorção Harmônica Total
DIC	Duração de Interrupção por Unidade Consumidora
DRC	Duração Relativa da Transgressão de Tensão Crítica
DRP	Duração Relativa da Transgressão de Tensão Precária
DSP	<i>Digital Signal Processor</i> (Processador digital de sinais)
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora

FIC	Frequência de Interrupção por Unidade Consumidora
FIR	<i>Finit Impulse Response</i>
GD	Geração Distribuída
HMM	<i>Hidden Markov Models</i>
ICC	Índice de Unidades Consumidoras com Tensão Crítica
IEEE	<i>Institute of Electrical and Electronic Engineering</i>
ITIC	<i>Information Technology Industry Council</i>
MCOV	<i>Maximun Continuous Operating Voltage</i>
PAC	Ponto de Acoplamento Comum
PDF	<i>Probabilistic Density Function</i> (Função densidade de probabilidade)
p.u.	Por Unidade
QEE	Qualidade da Energia Elétrica
QV	Quantização Vetorial
RBF	<i>Radial Basis Function</i>
RCT	Reatores Controlados por Tiristores
RNA	Rede Neural Artificial
RNP	Rede Neural Probabilística
STFT	<i>Short Time Fourier Transform</i>
TC	Transformador de Corrente
TF	Transformada de Fourier
TFJ	Transformada de Fourier Janelada
TP	Transformador de Potencial
TW	Transformada <i>Wavelet</i>
TWC	Transformada <i>Wavelet</i> Contínua
TWD	Transformada <i>Wavelet</i> Discreta

## LISTA DE SÍMBOLOS

$\mathbf{A}_{m \times m}$	Matriz quadrada qualquer
$a, a_0$	Parâmetros de dilatação
$a^1$	Vetor de saída da função de transferência RBF da RNP.
$a^2$	Vetor de saída da função de transferência competitiva $C$ na RNP
$b, b_0$	Parâmetros de translação
$b^1$	Vetor de polaridade
$C$	Função de transferência da RNP
$\mathbf{C}_x, \mathbf{C}_y$	Matrizes de covariâncias de $\mathbf{X}$ e $\mathbf{Y}$
$C_{CC}$	Capacitância CC
$cA$	Coefficientes de aproximação
$cD$	Coefficientes de detalhes
$c_o(n)$	Representação discreta de um sinal
$c_k(n)$	Coefficientes de aproximação ou de escala
$d_k(n)$	Coefficientes de detalhe ou <i>wavelet</i>
db4, dbn	Funções <i>wavelet</i> Daubechies com oito e “n” filtros
$f$	Frequência (60 Hz)
$f(t)$	Função qualquer

$freq_{Nivel}$	Frequência máxima representadas nos níveis da TW
$freq_s$	Frequência de amostragem
$g(n)$	Coefficientes do filtro passa-alta (filtro <i>wavelet</i> )
$h(n)$	Coefficientes do filtro passa-baixa (filtro de escala)
<b>I</b>	Matriz identidade
$i_{A,C}$	Correntes (fases A e C)
$i_{boost}$	Corrente produzida pelo conversor CC-CC
$i_{carga_{A,C}}$	Corrente da carga (fases A e C)
$I_{fonte}$	Corrente no alimentador
$j$	Escala
$K$ na RNP	Número de padrões de entrada da RNP
$k$	Número inteiro
$L$	Número níveis de decomposições da TW ( $L = 9$ )
$L_{boost}$	Indutância do boost
$L_{conv}, C_{conv}$	Filtro CA
$L_{grid}, R_{grid}$	Indutância e resistência da rede
$M, m$	Dimensão dos vetores característicos ( $M = L + 1$ )
$N, n$	Número total de sinais
$n^1$	Resultado da multiplicação $\ dist\  \times b^1$
$L_S$	Indutância série
$N^2$	Vetor de entrada da função competitiva C da rede neural
$\mathbf{P}_{m \times m}$	Matriz de transformação da ACP
$P_{SC}$	Potência media de curto-circuito do alimentador
$P_{fonte}$	Potência ativa entregue e/ou absorvida pelo alimentador

$p$	Número de componentes principais ( $p = 3$ )
$Q$	Número de combinações de entrada para saída da RNP
$Q \times R$	Dimensão de $W^1$ na RNP.
$Q_{fonte}$	Potência reativa entregue e/ou absorvida pelo alimentador
$R$	Dimensão do vetor $P$ na RNP.
$V_{AB_{ms}}$	Tensão de linha eficaz produzida pelo conversor CC-CA
$v_{A,C}$	Tensão de fase produzida pelo conversor CC-CA (fases A e C)
$V_m$	Subespaços da AMR
$V_{fonte}$	Tensões do alimentador
$V_{RS}$	Tensão média da fonte CC
$v_{CC}$	Tensão do barramento CC
$X$	Razão entre $X_{L_{grid}}$ e $R_{grid}$ (na equação 7.2).
$\mathbf{X}_{m \times n}$	Matriz de dados de dimensão $m \times n$
$\mathbf{x}_i$	Vetor característico de cada sinal com distúrbio
$W_m$	Subespaços <i>wavelets</i>
$W^1, W^2$	Matrizes de pesos da RNP
$\mathbf{Y}$	Representação decorrelacionada da matriz de dados $\mathbf{X}_{m \times n}$
$y$	Resultado da RNP
$\lambda_n$	Autovalores
$\gamma_n$	Autovetores
$\ dist\ $	Distância Euclidiana na RNP
$\downarrow 2$	<i>Dowsampling</i>
$\phi_{m,n}(t)$	Funções escalas

$\bigcap_{m=-\infty}^{\infty} V_m$	Intersecção dos subespaços $V_m$
$\mu_X$	Média dos coeficientes de aproximação
$\  \ $	Norma
$\beta_p$	Percentual de variância representada pelas $P$ componentes principais
$\langle \rangle$	Produto interno
$\oplus$	Soma ortogonal
$\uparrow 2$	<i>Upsampling</i>
$\bigcup_{m=-\infty}^{\infty} V_m$	União dos subespaços $V_m$
$\psi_{m,n}(t), \psi_{a,b}(t)$	Funções <i>wavelets</i>
$\sigma^2$	Variância
$\sigma, dp$	Desvio padrão

# SUMÁRIO

1 INTRODUÇÃO.....	20
1.1 Organização da Dissertação.....	23
2 FENÔMENOS RELACIONADOS À QUALIDADE DA ENERGIA.....	24
2.1 Distúrbios transitórios .....	24
2.1.1 Transitórios impulsivos .....	26
2.1.2 Transitórios oscilatórios .....	26
2.2 Variações de tensão de longa duração.....	28
2.2.1 Sobretensão.....	29
2.2.2 Subtensão.....	29
2.2.3 Interrupções sustentadas .....	29
2.3 Variações de tensão de curta duração.....	30
2.3.1 Interrupção.....	30
2.3.2 Afundamento de tensão .....	31
2.3.3 Elevação de tensão .....	33
2.4 Desequilíbrio de tensão .....	35
2.5 Distorções da forma de onda .....	36
2.5.1 Nível CC .....	37
2.5.2 Harmônicos.....	37
2.5.3 Interharmônicos .....	40
2.5.4 <i>Notching</i> .....	41
2.5.5 Ruídos.....	42
2.6 Flutuação de tensão .....	42
2.7 Variações na frequência do sistema .....	44
2.8 Considerações finais.....	44
3 A TRANSFORMADA <i>WAVELET</i> .....	45
3.1 Transformada <i>wavelet</i> contínua.....	46
3.1.1 Escalonamento.....	48
3.1.2 Translação.....	49
3.2 Transformada <i>wavelet</i> discreta .....	50
3.3 Análise de multiresolução .....	51
3.3.1 Equação de dilatação .....	53
3.3.2 Multiresolução e wavelets .....	53
3.4 Relação entre filtragem e análise multiresolução.....	55

3.4.1 Filtragem.....	55
3.4.2 Decomposição em múltiplos níveis.....	57
3.4.3 Reconstrução <i>wavelet</i> .....	57
3.4.4 Filtros de reconstrução .....	58
3.4.5 Reconstruindo as aproximações e os detalhes.....	59
3.4.6 Frequências em cada nível de decomposição.....	60
4.5 Considerações finais .....	63
4 APLICAÇÕES DA TRANSFORMADA <i>WAVELET</i> EM QUALIDADE DE ENERGIA...	64
Considerações finais .....	72
5 ANÁLISE DE COMPONENTES PRINCIPAIS .....	73
5.1 Mudança de base .....	74
5.2 Matriz de covariância .....	75
5.3 Resolvendo a ACP: autovalores e autovetores .....	77
5.4 Escolhendo as componentes .....	77
5.5 Exemplo numérico.....	78
5.6 Considerações finais .....	80
6 METODOLOGIA APLICADA PARA CLASSIFICAÇÃO DOS DISTÚRBIOS.....	81
6.1 Análise dos sinais .....	81
6.2 Extração de características.....	85
6.3 Redução de dados através da ACP .....	87
6.4 Método de classificação de distúrbios utilizando uma rede neural probabilística .....	89
6.5 Considerações finais .....	90
7 RESULTADOS DAS CLASSIFICAÇÕES DOS DISTÚRBIOS .....	92
7.1 Classificação de distúrbios típicos.....	92
7.1.1 Resultados das classificações sem a ACP .....	93
7.1.2 Resultados das classificações com a ACP.....	94
7.1.3 Comparações das classificações .....	97
7.2 Caracterização e reconhecimento de eventos que ocorrem na tensão medida no ponto onde um sistema de geração distribuída se conecta a uma rede de distribuição .....	98
7.2.1 Descrição do sistema analisado .....	99
7.2.2 Simulações do sistema de geração distribuída .....	101
7.2.3 Classificações dos eventos .....	103
7.3 Considerações finais .....	106
8 CONCLUSÕES E TRABALHOS FUTUROS .....	107
REFERÊNCIAS BIBLIOGRÁFICAS .....	109

# 1 INTRODUÇÃO

Nos últimos anos, a preocupação com a qualidade da energia elétrica suprida aos consumidores vem aumentando. Com a privatização do setor elétrico, as atividades relacionadas com a geração, transmissão e distribuição tendem a desenvolver um ambiente mais competitivo, o que motiva a busca pela eficiência e qualidade. A crescente preocupação com a qualidade da energia é uma consequência do desenvolvimento tecnológico que proporciona uma maior utilização de equipamentos e sistemas microprocessados sensíveis às perturbações do sistema elétrico. A própria instalação e conexão de sistemas de geração distribuída, bem como a ocorrência de distúrbios (*ilhamento*) nesses sistemas, têm levado consumidores e concessionárias a se preocuparem cada vez mais com a qualidade da energia elétrica suprida, pois a qualidade da energia elétrica pode ter um impacto econômico direto tanto para os clientes quanto para as concessionárias de energia.

O conceito de “Qualidade da Energia Elétrica” (QEE) está relacionado a um conjunto de alterações que podem ocorrer no sistema elétrico. Entre os muitos estudos encontrados na literatura, pode-se apresentar o assunto como qualquer distúrbio manifestado sobre as formas de onda de tensão ou de corrente de forma que esses distúrbios resultem em falhas ou más operações dos equipamentos eletro-eletrônicos tanto para os consumidores quanto para os dispositivos de proteção (DUGAN et al., 2003). Além disso, tais alterações podem ocorrer tanto nos sistemas de transmissão e distribuição como nas instalações de consumidores.

De maneira geral, em sistemas de potência, o termo qualidade da energia é sinônimo de qualidade da tensão, pois os sistemas supridores podem somente controlar a qualidade da tensão, não tendo nenhum controle sobre as correntes que as cargas particulares podem drenar. Como os sistemas de potência são projetados para operarem com tensão senoidal a uma determinada frequência (tipicamente 50 ou 60 Hz) e amplitude, qualquer desvio significativo na amplitude, frequência ou pureza da forma de onda é um potencial problema de qualidade da energia. Mesmo assim, na prática, existe uma relação muito próxima entre tensão e corrente. Apesar dos geradores poderem fornecer uma onda de tensão quase senoidal, a corrente que passa pela impedância do sistema pode causar uma variedade de distúrbios na tensão. Por exemplo, a corrente resultante de um curto-circuito faz a amplitude da tensão se reduzir ou desaparecer completamente (DUGAN et al., 2003).

Considerando a forma de onda da tensão, pode-se encontrar vários tipos de eventos tais como: *notches*, harmônicos, interrupções, elevações ou afundamentos de tensão, *flickers*,

impulsos como *spikes* e transitórios de chaveamento, etc. Estes eventos têm duração entre 50ns e alguns minutos com componentes espectrais atingindo 5 MHz (no caso de transitórios impulsivos). Como causas mais comuns é possível mencionar saída de unidades geradoras, chaveamentos de bancos de capacitores, curto-circuito nos sistemas elétricos, operação e conexão de cargas de grande porte, cargas com características não-lineares e descargas atmosféricas (IEEE Std 1159, 1995).

Atualmente, o conceito de QE tem sido debatido mundialmente, uma vez que não se obteve um consenso sobre a forma de quantificar essa qualidade. Por enquanto, o que se dispõe são normas nacionais ou recomendações internacionais apoiadas por órgãos como o IEEE nos EUA e o CIGRÉ na Europa. No caso do Brasil, algumas dessas recomendações estrangeiras são seguidas integralmente e outras adaptadas parcialmente para uso local. Algumas das principais recomendações que se aplicam ao estudo de distúrbios da qualidade de energia são destacadas a seguir. Para distorções harmônicas em geral se aplica a norma IEEE 519 (1992), que é uma recomendação bastante abrangente. A IEEE 1159 (1995) é uma prática recomendada pela IEEE para monitoração e interpretação apropriada dos fenômenos que causam problemas de qualidade da energia. No Brasil segue-se basicamente a norma americana com adaptações. Para a avaliação das flutuações, em particular o efeito *flicker*, tem-se a norma IEC 61000-4-15, que estabelece uma curva limite para o nível de *flicker*. A ANSI/IEEE Std. 446, conhecida como curva CBEMA, e que virou ITIC (*Information Technology Industry Council*) em 1994, foi adotada nos EUA como guia para fabricantes de equipamentos de informática. Porém, é conveniente salientar a Resolução nº. 505 da ANEEL (Agência Nacional de Energia Elétrica) que trata de níveis de tensão em regime permanente.

No Brasil, o processo de monitoração da qualidade do serviço oferecido pelas concessionárias baseou-se, principalmente, na coleta e no processamento dos dados de interrupção do fornecimento de energia elétrica (DEC e FEC) informados periodicamente pelas empresas a ANEEL. Os dados são tratados e avaliados pela Agência, que verifica o desempenho das concessionárias. Atualmente, está em implantação o Sistema ANEEL de Monitoração da Qualidade da Energia Elétrica, que dará a Agência acesso direto e automático às informações sobre a qualidade do fornecimento, sem que dependa de dados encaminhados pelas empresas. Por via telefônica, o Sistema permite imediata recepção dos dados sobre interrupção e restabelecimento do fornecimento de energia elétrica e conformidade dos níveis de tensão nos pontos em que os equipamentos de monitoração estão instalados. Assim ele mede os indicadores da qualidade do serviço prestado pelas concessionárias de energia.

Com o Sistema ANEEL, a Superintendência de Fiscalização dos Serviços de Eletricidade - SFE pode fazer um acompanhamento da qualidade de modo mais eficaz e, além disso, auditar os dados fornecidos pelas concessionárias. Os indicadores calculados pelo Sistema são: os de interrupção (DEC, FEC, DIC e FIC) relativos à duração e à frequência das interrupções, por conjunto de consumidores e por consumidor individual; os de níveis de tensão (DRP, DRC e ICC) relativos à ocorrência da entrega de energia ao consumidor com tensões fora dos padrões de qualidade definidos pela ANEEL, cujas definições se encontram nas Resoluções nº. 024 e 505 da ANEEL. No entanto, estes índices estão relacionados somente com níveis em que a tensão está sendo suprida, intervalo de tempo em que o sistema permanece sem energia e a frequência de tais desligamentos. Sendo assim, estes índices não detectam certas alterações ou distúrbios nas formas de onda e na frequência, como ruídos e distorções harmônicas, que podem acarretar problemas operacionais nos equipamentos dos consumidores. Além disso, a crescente quantidade de dados obtidos através do monitoramento da qualidade de energia elétrica requer não só uma precisa análise, mas também uma caracterização, classificação e compreensão desses dados de forma automática.

Diante disso, fica evidente a necessidade de estudos e propostas que visem o desenvolvimento de interfaces que venham propiciar uma análise adequada e automatizada no contexto de QE. Por isso há a necessidade de estudar e analisar diversos fenômenos e distúrbios que ocorrem nos sistemas de energia de baixa, média e alta tensão e então desenvolver algoritmos que identifiquem precisamente alguns fenômenos específicos que degradam a qualidade da energia elétrica.

Diversos trabalhos têm apresentado diferentes metodologias para a identificação de distúrbios utilizando modernas ferramentas para análise de sinais. Dentre elas pode-se destacar a transformada *wavelet* (TW) e as redes neurais artificiais (SANTOSO et al., 2000). A TW tem atraído a atenção da comunidade científica na análise da qualidade da energia devido a sua capacidade de decompor sinais em múltiplas bandas de frequência com resolução otimizada. Já as redes neurais têm sido aplicadas em QE justamente por oferecerem um alto potencial de reconhecimento de padrões que permite identificar os diferentes distúrbios que afetam a QEE.

Motivado pelas situações acima, este trabalho propõe estudos utilizando os modernos métodos para a análise de sinais tais como a transformada *wavelet* (TW), análise de componentes principais e redes neurais artificiais, para a análise e processamento de sinais elétricos. Tais ferramentas permitem identificar e caracterizar diversos distúrbios de qualidade

da energia elétrica que ocorrem em qualquer parte dos sistemas elétricos, visto que o tema “qualidade de energia” se aplica a qualquer local do sistema elétrico e a qualquer tipo de consumidor. A metodologia apresentada nesta dissertação propõe além da utilização da TW e redes neurais para a classificação de distúrbios, a aplicação da análise de componentes principais (ACP) com o intuito de reduzir o número de dados a serem classificados pela rede neural. E ainda, considerando um substancial aumento no interesse em sistemas de geração distribuída GD, são realizadas análises em sinais de tensão provindos de simulações de um sistema de GD conectado em uma rede de distribuição utilizando-se a mesma metodologia.

### **1.1 Organização da Dissertação**

O primeiro capítulo apresenta uma introdução que aborda o tema qualidade da energia elétrica e também destaca a problemática e alguns métodos de análises aplicados ao tema. A teoria referente à QEE é apresentada no capítulo 2. O capítulo 3 mostrará uma revisão bibliográfica dos principais trabalhos estudados que aplicam a transformada *wavelet* no contexto da QEE. A fundamentação teórica da TW e a análise de componentes principais, que são as principais ferramentas utilizadas no trabalho, são apresentadas nos capítulos 4 e 5, respectivamente. Em seguida, o capítulo 6 mostra a metodologia proposta para análise e classificação dos distúrbios relacionados à QEE. Os resultados das análises realizadas com o algoritmo construído são apresentados no capítulo 7. Já o capítulo final apresta as principais conclusões e possíveis seqüências para esta dissertação.

## **2 FENÔMENOS RELACIONADOS À QUALIDADE DA ENERGIA**

O termo qualidade da energia elétrica é aplicado a uma grande variedade de fenômenos eletromagnéticos que ocorrem nos sistemas elétricos de potência. Nos últimos anos, a aplicação crescente de equipamentos eletrônicos e a geração distribuída despertaram ainda mais o interesse com a qualidade da energia elétrica. Considera-se como distúrbio qualquer evento que provoque a deterioração da energia elétrica em termos de forma de onda senoidal de amplitude e frequência constante.

Esta etapa do trabalho visa apresentar os conceitos básicos, origens e conseqüências de alguns dos fenômenos eletromagnéticos mais importantes relacionados à qualidade da energia. Esses fenômenos (distúrbios) que o sistema elétrico está exposto podem ser classificados de diversas formas, dependendo dos efeitos que produzem, da faixa de frequências características, da duração dos eventos, etc. Uma classificação para estes distúrbios é apresentada na Tabela 2.1, extraída da referência (DUGAN et al., 2003). A Tabela 2.1 mostra as categorias e as características típicas dos fenômenos que contribuem para a perda da qualidade da energia. Neste capítulo, são apresentados e definidos cada um dos distúrbios especificados na Tabela 2.1 de acordo com suas classes e subclasses. Além das definições, são apresentadas algumas das principais causas e possíveis conseqüências desses fenômenos que contribuem para degradação da qualidade da energia. As maneiras como os distúrbios se manifestam nas formas de onda da tensão e/ou corrente são melhores visualizadas nas figuras apresentadas no decorrer do capítulo.

### **2.1 Distúrbios transitórios**

O termo transitório tem sido aplicado à análise das variações do sistema de energia para denotar um evento indesejável e momentâneo em sua natureza (DUGAN et al., 2003). Distúrbios transitórios são decorrentes das variações instantâneas na corrente, as quais interagem com sua impedância, resultando em elevadas tensões instantâneas. No sistema elétrico, existem duas principais fontes de transitórios: chaveamento de capacitores e descargas atmosféricas. Adicionalmente, alguns equipamentos eletrônicos e conexão de cargas também podem gerar transitórios significativos no sistema.

Tabela 2.1 – Categorias e características típicas dos fenômenos eletromagnéticos típicos nos sistemas elétricos de potência (DUGAN et al., 2003).

<b>Categoria</b>	<b>Conteúdo Espectral Típico</b>	<b>Duração Típica</b>	<b>Amplitude de Tensão Típica</b>
1.0 Transitórios			
1.1 Impulsivos			
1.1.1 Nanosegundo	5 ns	<50 ns	
1.1.2 Microsegundo	1 $\mu$ s	50 ns – 1 ms	
1.1.3 Milisegundo	0,1 ms	> 1 ms	
1.2 Oscilatórios			
1.2.1 Baixa Frequência	< 5 kHz	3 – 50 ms	0,4 pu
1.2.2 Média Frequência	5 – 500 kHz	20 $\mu$ s	0,4 pu
1.2.3 Alta Frequência	0,5 – 5 MHz	5 $\mu$ s	0,4 pu
2.0 Variações de Tensão de Curta Duração			
2.1 Instantânea			
2.1.1 Interrupção		0,5 – 30 ciclos	<0,1 pu
2.1.2 Afundamento		0,5 – 30 ciclos	0,1 – 0,9 pu
2.1.3 Elevação		0,5 – 30 ciclos	1,1 – 1,8 pu
2.2 Momentânea			
2.2.1 Interrupção		30 ciclos – 3 s	<0,1 pu
2.2.2 Afundamento		30 ciclos – 3 s	0,1 – 0,9 pu
2.2.3 Elevação		30 ciclos – 3 s	1,1 – 1,4 pu
2.3 Temporária			
2.3.1 Interrupção		3 s – 1 minuto	<0,1 pu
2.3.2 Afundamento		3 s – 1 minuto	0,1 – 0,9 pu
2.3.3 Elevação		3 s – 1 minuto	1,1 – 1,2 pu
3.0 Variações de Tensão de Longa Duração			
3.1 Interrupção Sustentada		> 1 minuto	0,0 pu
3.2 Subtensão Sustentada		> 1 minuto	0,8 – 0,9 pu
3.3 Sobretensão Sustentada		> 1 minuto	1,1 – 1,2 pu
4.0 Desequilíbrio de Tensão		Regime permanente	0,5 – 2%
5.0 Distorção da Forma de Onda			
5.1 Nível CC		Regime permanente	0 – 0,1%
5.2 Harmônicos	De ordem 0 – 100	Regime permanente	0 – 20%
5.3 Interharmônicos	0 – 6 kHz	Regime permanente	0 – 2%
5.4 <i>Notching</i>		Regime permanente	
5.5 Ruído		Regime permanente	0 – 1%
6.0 Flutuação de Tensão	< 25 Hz	intermitente	0,1 – 0,7%
7.0 Variação da Frequência do Sistema		< 10 s	

Os fenômenos transitórios podem ser classificados em dois grupos: os transitórios impulsivos, causados principalmente por descargas atmosféricas, e os transitórios oscilatórios, causados por chaveamentos de capacitores.

### 2.1.1 Transitórios impulsivos

Um transitório impulsivo pode ser definido como uma súbita alteração nas condições de regime permanente, refletindo nas formas de ondas da tensão, corrente ou em ambas, sendo unidirecional na sua polaridade (positiva ou negativa), ou seja, há uma grande variação na tensão e/ou corrente em um único sentido. Como já mencionado, os transitórios impulsivos são decorrentes principalmente das descargas atmosféricas cuja frequência do sinal difere daquela encontrada na rede elétrica (DUGAN et al., 2003). Como exemplificação, a Figura 2.1 mostra uma corrente transitória impulsiva típica, causada por uma descarga atmosférica.

Os transitórios impulsivos podem ser definidos tanto pelo tempo de subida e de descida do impulso quanto pelo seu conteúdo espectral.

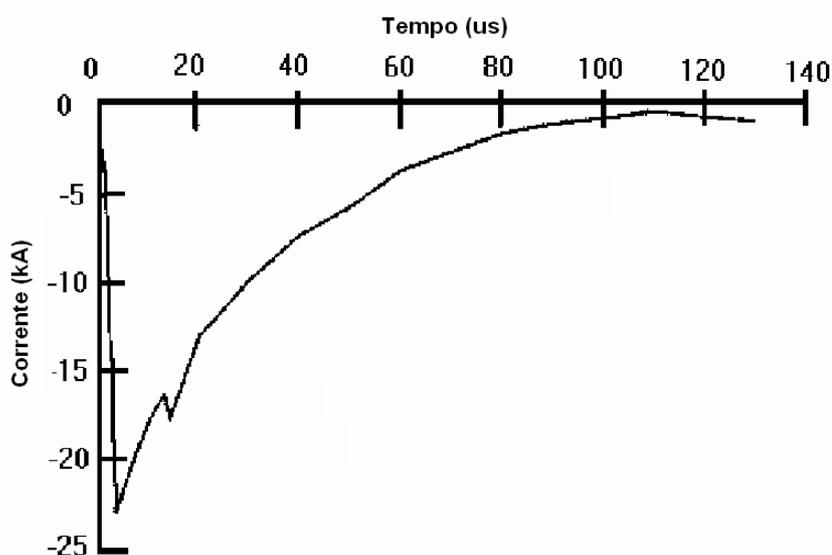


Figura 2.1 – Corrente transitória impulsiva causada por uma descarga atmosférica (IEEE Std 1159, 1995).

Devido às altas frequências envolvidas, os transitórios impulsivos são amortecidos rapidamente pelos componentes resistivos do circuito, o que significa que seu efeito não é propagado ao longo da rede.

### 2.1.2 Transitórios oscilatórios

Um transitório oscilatório pode ser definido como uma súbita alteração não desejável da condição de regime permanente da tensão, corrente, ou ambas, que fazem com que estas variáveis oscilem transitoriamente numa frequência maior do que a frequência fundamental do sistema.

Os transitórios oscilatórios com uma componente de frequência primária maior que 500 kHz e uma duração típica medida em microssegundos (ou vários ciclos da frequência principal) são considerados transitórios oscilatórios de alta frequência. Estes transitórios são decorrentes de uma resposta local do sistema a um transitório impulsivo e podem ser causados por descargas atmosféricas ou por chaveamentos de circuitos indutivos.

Um transitório com uma componente de frequência primária entre 5 e 500 kHz com duração medida em dezenas de microssegundos (ou vários ciclos da frequência principal), é referenciado como transitório de média frequência. A energização de capacitores *back-to-back* resulta em correntes oscilatórias transitórias de dezenas de quilohertz como ilustrado na Figura 2.2 da referência (IEEE Std 1159, 1995), sendo que esses distúrbios são ocasionados quando o sistema de potência é submetido a um impulso transitório (DUGAN et al., 2003).

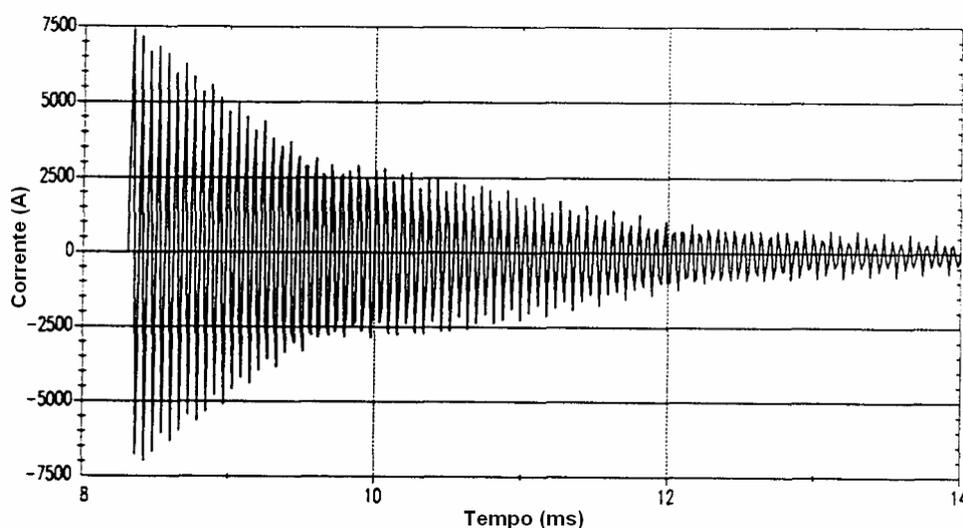


Figura 2.2 – Corrente transitória oscilatória causada pelo chaveamento de capacitores *back-to-back* (IEEE Std 1159, 1995).

Um transitório com uma componente de frequência primária menor que 5 kHz e duração entre 0,3 e 50 ms é considerado um transitório oscilatório de baixa frequência, sendo que este tipo de fenômeno é encontrado nos sistemas de sub-transmissão e de distribuição das concessionárias. O evento mais comum capaz de produzir um transitório oscilatório de baixa

freqüência é a energização de bancos de capacitores, que resulta em uma tensão oscilatória transitória com uma freqüência primária entre 300 e 900 Hz e um pico que pode alcançar 2,0 p.u. Tipicamente, a amplitude decorrente desses fenômenos pode alcançar valores 1,3 a 1,5 p.u. com uma duração entre 0,5 e 3 ciclos dependendo do amortecimento, Figura 2.3.

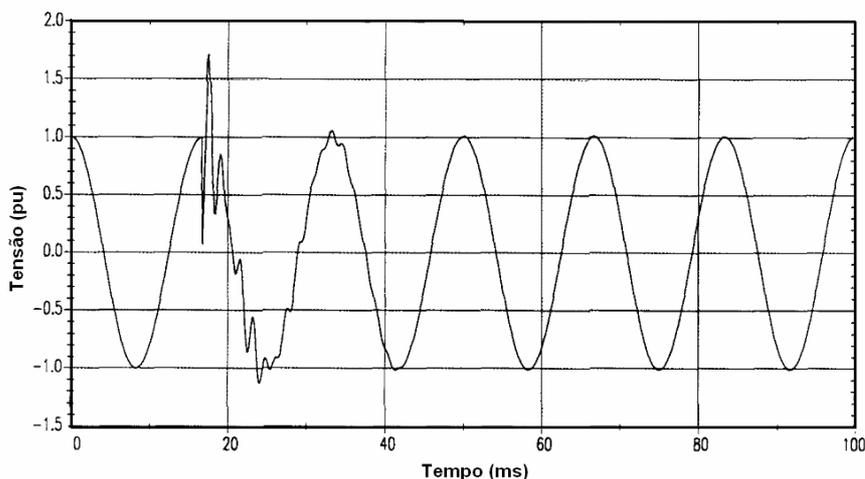


Figura 2.3 – Transitório oscilatório de baixa freqüência causado pela energização de banco de capacitores (IEEE Std 1159, 1995).

Os transitórios oscilatórios com freqüências menores que 300 Hz também podem ser encontrados nos sistemas de distribuição. Estes são geralmente associados aos fenômenos de ferro-ressonância e energização de transformadores. Transitórios envolvendo capacitores em série podem ser incluídos nesta categoria. Estes ocorrem quando o sistema responde pela ressonância com componentes de baixa freqüência na corrente de magnetização do transformador (segunda e terceira harmônica) ou quando condições não usuais resultam em ferro-ressonância.

## 2.2 Variações de tensão de longa duração

Variações de longa duração na tensão são caracterizadas como desvios que ocorrem no valor eficaz da tensão, na freqüência de 50 ou 60 Hz, por um período superior a 1 minuto. Estas variações podem ser subtensões, sobretensões ou interrupções sustentadas. Sobretensões e subtensões geralmente não resultam em faltas, mas podem ser causadas por variações de carga no sistema e operações de chaveamento sobre o mesmo. Tais variações são tipicamente mostradas como gráficos da tensão eficaz *versus* tempo (DUGAN et al., 2003).

### 2.2.1 Sobretensão

Uma sobretensão é um incremento de no mínimo 10% no valor eficaz da tensão em relação ao seu valor nominal (valores típicos entre 1,1 e 1,2 p.u.) na mesma frequência fundamental, sendo que sua duração deve ser superior a 1 minuto (Tabela 2.1). Sobretensões resultam normalmente do desligamento de grandes cargas ou energização de bancos de capacitores. Isto ocorre porque o sistema é fraco ou os controles de tensão são inadequados. *Taps* de transformadores ajustados incorretamente também podem resultar em sobretensões.

### 2.2.2 Subtensão

Uma subtensão é um decréscimo no valor eficaz da tensão CA para menos de 90% do seu valor nominal e duração superior a 1 minuto (Tabela 2.1).

As subtensões resultam de eventos de chaveamento que são os opostos dos eventos que causam as sobretensões. A conexão de grandes cargas ou o desligamento de bancos de capacitores podem causar subtensões até que o equipamento regulador de tensão no sistema possa trazer a tensão de volta ao limites de tolerância. Os desligamentos de bancos de capacitores aumentam os reativos transportados pelos circuitos de distribuição limitando a capacidade do sistema no fornecimento de potência ativa e ao mesmo tempo, a queda de tensão é incrementada.

### 2.2.3 Interrupções sustentadas

Quando o fornecimento de tensão permanece zero por um período de tempo que excede 1 minuto, a variação de tensão de longa duração é considerada como uma interrupção sustentada. As interrupções de tensão com duração superior a 1 minuto são consideradas permanentes e requerem intervenção humana para reparar o sistema e restabelecer o fornecimento normal de energia (DUGAN et al., 2003).

As interrupções sustentadas podem ocorrer de forma inesperada ou de forma planejada. A maioria delas ocorre inesperadamente e as principais causas são: falhas nos disjuntores, queima de fusíveis, falha de componentes de circuito alimentador, etc. Já as interrupções planejadas são feitas geralmente para executar transferência de carga ou

manutenção na rede, ou seja, serviços como: troca de cabos e postes, mudança do tap do transformador, alteração dos ajustes de equipamentos de proteção, etc.

### 2.3 Variações de tensão de curta duração

Estas variações podem ser designadas como instantâneas, momentâneas ou temporárias de acordo com as definições encontradas na Tabela 2.1. Variações de tensão de curta duração são causadas por condições de falta, energização de grandes cargas que requerem altas correntes de partida ou perda intermitente de conexões nos cabos do sistema. Dependendo da localização da falta e das condições do sistema, a falta pode causar ou decréscimos na tensão (afundamentos, *sags*), ou aumentos na tensão (elevações, *swells*) ou ainda, uma completa perda da tensão (interrupções).

#### 2.3.1 Interrupção

Uma interrupção ocorre quando o fornecimento de energia ou corrente de carga decresce para um valor menor do que 0,1 p.u. por um período de tempo que não excede 1 minuto (IEEE Std 1159, 1995).

As interrupções podem ser resultantes de faltas no sistema de energia, falhas nos equipamentos e mau funcionamento dos sistemas de controle. As interrupções são medidas pelas suas durações desde que a magnitude da tensão seja menor do que 10% de seu valor nominal. A duração de uma interrupção devido ao mau funcionamento de equipamentos é irregular. Já a duração de uma interrupção, devido a uma falta no sistema da concessionária, é determinada pelo tempo de operação dos dispositivos de proteção do sistema. Religadores instantâneos limitam a interrupção causada por uma falta não permanente a tempos inferiores a 30 ciclos. Religadores temporizados podem causar interrupções momentâneas ou temporárias (Tabela 2.1), dependendo da escolha das curvas de operação dos equipamentos de proteção.

Algumas interrupções podem ser precedidas por um afundamento de tensão quando estas são decorrentes de faltas no sistema supridor. O afundamento ocorre no período de tempo entre o início de uma falta e a operação do dispositivo de proteção. A Figura 2.4 mostra uma interrupção momentânea devido a um curto-circuito, sendo precedida por um afundamento.

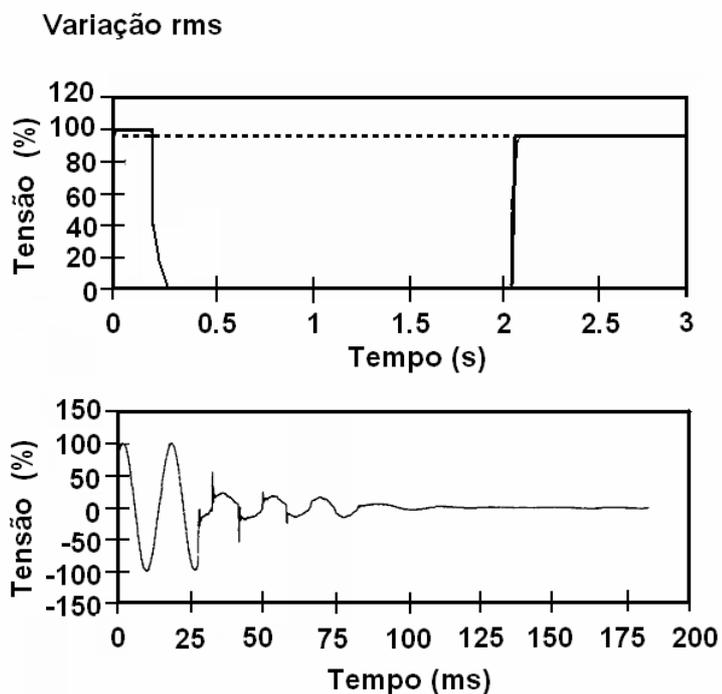


Figura 2.4 – Interrupção momentânea devido a um curto-circuito e subsequente religamento (IEEE Std 1159, 1995).

### 2.3.2 Afundamento de tensão

Em um afundamento de tensão de curta duração ou “*voltage sag*”, o valor nominal de tensão deve ficar entre 0,1 e 0,9 p.u., na mesma frequência fundamental, e sua duração ser de 0,5 ciclos até 1 minuto (DUGAN et al., 2003). Estudos mais aprofundados sobre afundamentos de tensão podem ser encontrados em (BOLLEN, 1999).

Dependendo da duração estes eventos podem estar associados a três categorias, sendo estas: instantâneas, momentâneas e temporárias, as quais coincidem com as três categorias das interrupções e elevações já comentadas. Estes tempos de permanência sobre o sistema correspondem aos tempos de operação que são típicos dos dispositivos de proteção das concessionárias e das divisões recomendadas pelas organizações técnicas internacionais.

Os afundamentos de tensão são geralmente associados com faltas no sistema, mas também podem ser causados pela energização de grandes cargas, partidas de grandes motores ou pela corrente de magnetização de um transformador. As características de um afundamento de tensão diante de uma determinada falta dependem de vários fatores como: a natureza da falta, sua posição relativa a outros consumidores ligados a rede e o tipo de filosofia adotada

no sistema. A Figura 2.5, obtida na referência (IEEE Std 1159, 1995), ilustra um afundamento de tensão típico causado por uma falta fase-terra. Observa-se um decréscimo de 80% na tensão por um período de aproximadamente 3 ciclos, até que o equipamento de proteção da subestação opere e elimine a corrente de falta. Neste caso, de acordo com a Tabela 2.1, o afundamento é de caráter instantâneo, pois possui uma duração de aproximadamente 3 ciclos. O tempo de eliminação de uma falta varia de 3 a 30 ciclos, dependendo da magnitude da corrente de falta e do tipo de proteção para sobrecorrente.

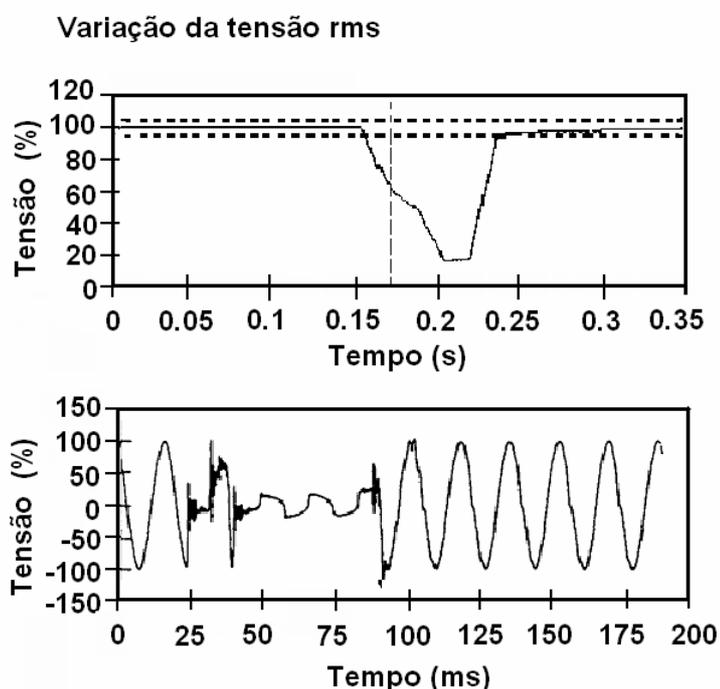


Figura 2.5 – Afundamento de tensão causado por uma falta fase-terra (IEEE Std 1159, 1995).

A Figura 2.6 ilustra o efeito de um grande motor partindo. Um motor de indução absorve uma corrente de 6 a 10 vezes sua corrente de carga nominal durante a partida. Se a magnitude da corrente é comparável à corrente de curto-circuito do sistema naquele ponto, o afundamento resultante pode ser significativo. Neste caso, observa-se que, o afundamento da tensão é de 20% e retorna gradualmente a seu valor nominal em aproximadamente 3 segundos.

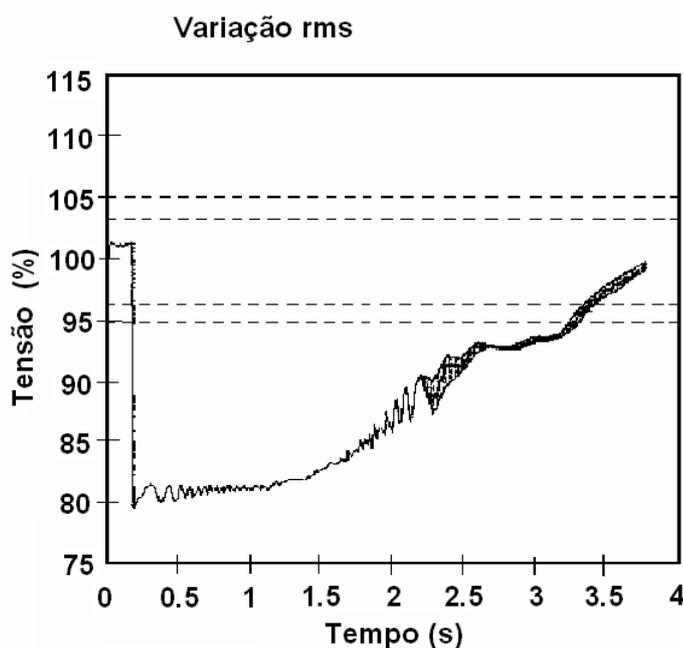


Figura 2.6 – Afundamento de tensão temporário causado pela partida de um motor de indução (IEEE Std 1159, 1995).

Como efeito destes distúrbios tem-se, principalmente, a má operação de equipamentos eletrônicos, em especial os computadores, que tem sido alvo de preocupações em órgãos de pesquisa em qualidade da energia elétrica.

### 2.3.3 Elevação de tensão

Uma elevação de tensão de curta duração ou "*voltage swell*" é definida como um aumento entre 1,1 e 1,8 p.u. na tensão eficaz e com duração entre 0,5 ciclo a 1 minuto (Tabela 2.1). Este distúrbio ocorre nas fases não afetadas de um circuito trifásico, quando da ocorrência de um curto-circuito em uma única fase (fase-terra).

Assim como os afundamentos, as elevações estão geralmente associadas com as condições de falta no sistema, mas não são tão comuns quanto os afundamentos de tensão. Um meio ilustrativo de como uma elevação pode ocorrer é visto na Figura 2.7. Este fenômeno pode também estar associado à saída de grandes blocos de cargas ou a energização de grandes bancos de capacitores, porém, com uma incidência pequena se comparada com as sobretensões provenientes de faltas fase-terra nas redes de transmissão e distribuição.

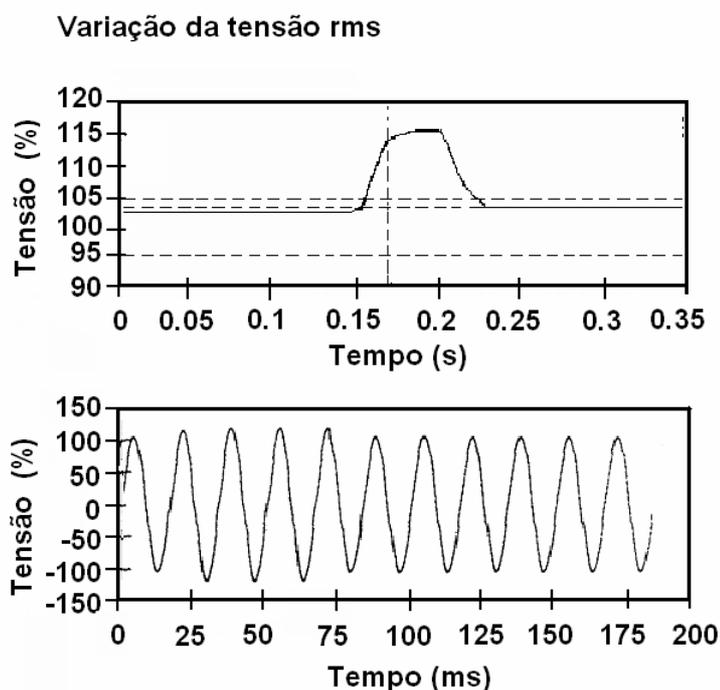


Figura 2.7 – Elevação de tensão devido a uma falta fase-terra (IEEE Std 1159, 1995).

As elevações são caracterizadas pelas suas magnitudes (valores eficazes) e suas durações. A severidade deste distúrbio durante uma condição de falta é função do local da falta, da impedância do sistema e do aterramento.

A duração da sobretensão está intimamente ligada aos ajustes dos dispositivos de proteção, à natureza da falta (permanente ou temporária) e à sua localização na rede elétrica. Em situações de elevações oriundas de saídas de grandes cargas ou energização de grandes bancos capacitores, o tempo de duração das elevações depende da resposta dos dispositivos reguladores de tensão das unidades geradoras, do tempo de resposta dos transformadores de *tap* variável e da atuação dos dispositivos compensadores como RCT's (reatores controlados por tiristores), CCT's (capacitores controlados por tiristores) e compensadores síncronos (máquinas síncronas) que porventura existam no sistema.

Dispositivos eletrônicos incluindo os ASD's (*Adjustable Speed Drivers*), computadores e controladores eletrônicos podem apresentar falhas imediatas durante estas condições. Além do mais, transformadores, cabos, barramentos, dispositivos de chaveamento, TP's, TC's e máquinas rotativas podem ter a vida útil reduzida. Um aumento de curta duração na tensão em alguns relés pode resultar em má operação enquanto outros podem não ser afetados. Uma elevação de tensão em um banco de capacitores pode causar danos ao equipamento. Aparelhos de iluminação podem ter um aumento da luminosidade durante uma elevação. Dispositivos de proteção contra surto, como um circuito de fixação da amplitude

(*clamping circuit*), podem ser destruídos quando submetidos a elevações que excedam suas taxas de MCOV (*Maximun Continuous Operating Voltage*).

Dentro do exposto acima, a preocupação principal recai sobre os equipamentos eletrônicos, uma vez que estas elevações podem vir a danificar os componentes internos destes equipamentos, conduzindo-os à operação inadequada, ou em casos extremos, a sua inutilização. É relevante observar que a suportabilidade de um equipamento não depende apenas da magnitude da elevação, mas também do seu período de duração. Isto vale também para o caso dos afundamentos. Sendo assim, foi estabelecido pela ANSI/IEEE (*American National Standards Institute/ Institute of Electrical and Electronic Engineering*) limites de tolerância relativos a distúrbios no sistema elétrico, conforme ilustra a Figura 2.8, que mostra as tolerâncias típicas de microcomputadores às variações de tensão sem apresentar falhas (curva CBEMA – *Computer Business Equipment Manufacturers Association*).

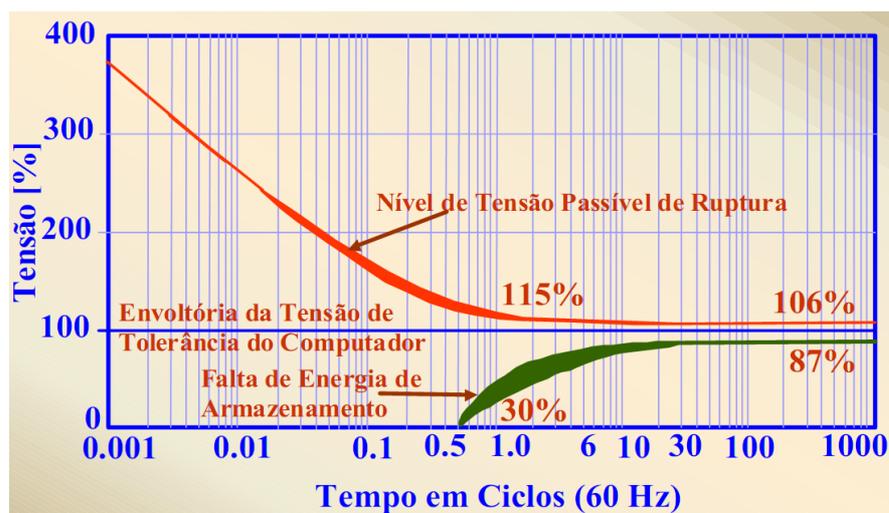


Figura 2.8 – Tolerâncias típicas de tensão para computadores (curva CBEMA).

## 2.4 Desequilíbrio de tensão

Desequilíbrio de tensão, em geral, é definido como o desvio máximo dos valores médios das tensões ou correntes (trifásicas), dividido pela média dos mesmos valores, expresso em percentagem, como na equação (2.1), sendo  $V_{ab}, V_{bc}, V_{ca}$  as tensões de fase.

$$deseq(\%) = \frac{\text{máximo desvio da média de } \{V_{ab}, V_{bc}, V_{ca}\}}{\text{média de } \{V_{ab}, V_{bc}, V_{ca}\}} \times 100\% \quad (2.1)$$

O desequilíbrio também pode ser definido através da teoria de componentes simétricos. A razão entre os componentes ou de seqüência negativa ou zero, com o componente de seqüência positiva pode ser usado para especificar a percentagem do desequilíbrio.

As origens destes desequilíbrios estão geralmente nos sistemas de distribuição, os quais possuem cargas monofásicas distribuídas inadequadamente, fazendo surgir no circuito tensões de seqüência negativa. Este problema se agrava quando consumidores supridos por rede trifásica, possuem uma má distribuição de carga que impõe correntes desequilibradas no PAC (ponto de acoplamento comum entre a concessionária e os consumidores). Além disso, tensões desequilibradas podem ser decorrentes da queima de fusíveis em uma fase de um banco de capacitores trifásicos. Pois a ausência de capacitores em uma das fases irá aumentar os reativos e diminuir a potência ativa disponível em relação às outras fases que continuarem a ter capacitores conectados.

Tais fatores fazem com que a qualidade no fornecimento de energia visada pela concessionária seja prejudicada e desta forma, alguns consumidores têm desequilíbrios na energia fornecida pela concessionária, a qual se manifesta sob três formas distintas:

- amplitudes diferentes;
- assimetria nas fases;
- assimetria conjunta de amplitudes e fases.

Destas, apenas a primeira é frequentemente evidenciada no sistema elétrico (OLESKOVICZ, 2004).

## 2.5 Distorções da forma de onda

A distorção da forma de onda é definida como um desvio em regime permanente da forma de onda puramente senoidal na frequência fundamental e é caracterizada quando o seu conteúdo espectral é analisado (DUGAN et al., 2003).

Há cinco tipos principais de distorções da forma de onda - Tabela 2:

- Nível de corrente contínua (CC);
- Harmônicos;
- Inter-harmônicas;
- *Notching*;
- Ruídos.

### 2.5.1 Nível CC

A presença de uma tensão ou corrente CC em um sistema de energia é denominada nível CC (*dc offset*). Este pode ocorrer como resultado de um distúrbio ou devido à operação de retificadores de meia-onda. O nível CC em redes de corrente alternada pode ter um efeito prejudicial, pois pode levar os núcleos de transformadores à saturação, causando sobreaquecimento e diminuição de sua vida útil. Além de causar corrosão eletrolítica dos eletrodos de aterramento e de outros conectores.

### 2.5.2 Harmônicos

Harmônicas são tensões ou correntes senoidais de frequências múltiplas inteiras da frequência fundamental na qual o sistema elétrico de energia opera.

Os conteúdos harmônicos distorcem a forma de onda da tensão e corrente e são oriundos de dispositivos e cargas com características não-lineares instalados no sistema de energia (rede de distribuição ou transmissão). É um tipo específico de energia “suja”, que é normalmente associada com a crescente quantidade de acionamentos estáticos, fontes chaveadas e outros dispositivos eletrônicos nas plantas industriais. Estes dispositivos podem ser freqüentemente modelados como fontes de corrente que injetam correntes harmônicas no sistema. Estas correntes originam quedas de tensão não-lineares ao longo da impedância do sistema causando distorções de tensão (IEEE Std 1159, 1995).

Harmônicos são fenômenos contínuos e não devem ser confundidos com fenômenos de curta duração, os quais duram apenas alguns ciclos. Estas perturbações no sistema podem normalmente ser eliminadas com a aplicação de filtros de linha (supressores de transitórios). Um filtro de harmônicos pode ser simples como um capacitor ou um indutor (denominados filtros passivos), ou complexo como os filtros ativos baseados em sofisticados dispositivos de eletrônica de potência.

A distorção harmônica vem contra os objetivos da qualidade do suprimento promovido por uma concessionária de energia elétrica, a qual deve fornecer aos seus consumidores uma tensão puramente senoidal, com amplitude e frequência constantes. Entretanto, o fornecimento de energia a determinados consumidores que causam deformações no sistema supridor, prejudica não apenas o consumidor responsável pelo distúrbio, mas também demais consumidores conectados à mesma rede elétrica.

Para a quantificação do grau de distorção presente na tensão e/ou corrente, lança-se mão da ferramenta matemática conhecida por série de Fourier. As vantagens de se usar a série de Fourier para representar formas de onda distorcidas é que, cada componente harmônica pode ser analisada separadamente e a distorção final é determinada pela superposição das várias componentes constituintes do sinal distorcido.

Conhecidos os valores de tensões e/ou correntes harmônicas presentes no sistema, utiliza-se de um procedimento para expressar o conteúdo harmônico de uma forma de onda. Um dos mais utilizados é a "Distorção Harmônica Total" (*Total Harmonic Distortion, THD*), a qual pode ser empregada tanto para sinais de tensão como para correntes:

$$DHT = \frac{\sqrt{\sum_{h=2}^{h_{\max}} M_h^2}}{M_1} \quad (2.2)$$

onde  $M_h$  é o valor eficaz da componente harmônica  $h$  da quantidade  $M$ .

Para fins práticos, as harmônicas de ordens elevadas (acima da 50ª ordem, dependendo do sistema) são desprezíveis para análises de sistemas de potência, apesar de poderem causar interferência em dispositivos eletrônicos de baixa potência.

A Figura 2.9, da referência (OLESKOVICZ, 2004), ilustra um perfil da vida útil de um transformador de corrente que se estabelece através de seus enrolamentos. Os resultados consideram que as componentes harmônicas, para cada situação, são superpostas a uma corrente fundamental igual a corrente nominal do equipamento.

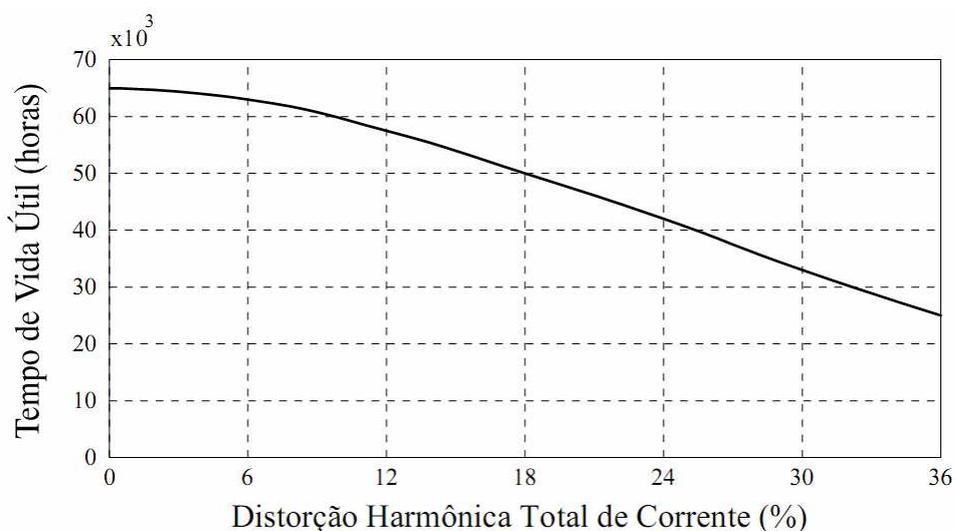


Figura 2.9 – Vida útil de um transformador em função da distorção harmônica de corrente.

Até os anos 80 não existiam maiores preocupações com distorções harmônicas. Cargas com características não-lineares eram pouco utilizadas e os equipamentos eram mais resistentes aos efeitos provocados por distorções harmônicas. Entretanto, nos últimos anos, com o rápido desenvolvimento da eletrônica de potência e a utilização de métodos que buscam o uso mais racional de energia elétrica, o conteúdo harmônico presente nos sistemas tem se elevado. Isto vem causando uma série de efeitos indesejáveis em diversos equipamentos ou dispositivos, comprometendo a qualidade e o próprio uso racional da energia elétrica. O problema é ainda agravado com a utilização de equipamentos e cargas mais sensíveis às perturbações na QEE (ARRUDA, 2003).

Assim, é de grande importância citar os vários tipos de cargas elétricas com características não-lineares, que têm sido implantadas em grande quantidade no sistema elétrico brasileiro. Estas, de um modo geral, podem ser classificadas em três grupos básicos:

a) Cargas de conexão direta ao sistema

- motores de corrente alternada;
- transformadores alimentadores saturados;
- circuitos de iluminação com lâmpadas de descarga;
- fornos a arco;
- compensadores estáticos tipo reator saturado, etc.

b) Cargas conectadas através de conversores

- motores de corrente contínua controlados por retificadores;
- motores de indução controlados por inversores;
- processos de eletrólise através de retificadores não-controlados;
- motores síncronos controlados por cicloconversores;
- fornos de indução de alta frequência, etc.

c) Reguladores

- fornos de indução controlados por reatores saturados;
- cargas de aquecimento controladas por tiristores;
- velocidade dos motores CA controlados por tensão de estator;
- reguladores de tensão a núcleo saturado;
- computadores;
- eletrodomésticos com fontes chaveadas, etc.

Os principais problemas causados por harmônicos, no entanto, se dão junto a bancos de capacitores, que podem originar condições de ressonância, caracterizando uma sobretensão nos terminais das unidades capacitivas. Em decorrência desta sobretensão, tem-se uma degradação do isolamento das unidades capacitivas, e em casos extremos, a queima dos capacitores. Além disso, consumidores conectados no mesmo ponto ficam submetidos a tensões perigosas, mesmo não sendo portadores de cargas poluidoras em sua instalação, o que estabelece uma condição extremamente prejudicial à operação de diversos equipamentos.

Mesmo que não seja caracterizada uma condição de ressonância, um capacitor é sempre um caminho de baixa impedância para as correntes harmônicas, e na presença delas, ele se encontrará constantemente sobrecarregado, e sujeito a sobreaquecimento excessivo, podendo ocorrer a atuação da proteção, sobretudo dos relés térmicos. Estes efeitos, isolados ou conjuntamente, resultam na diminuição da vida útil do capacitor, como mostra a Figura 2.10 (OLESKOVICZ, 2004).

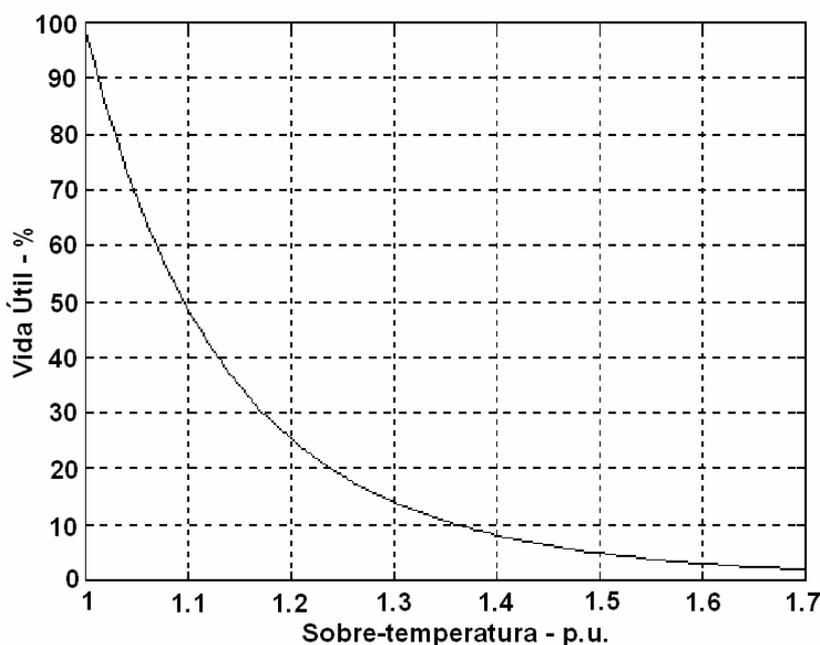


Figura 2.10 – Vida útil *versus* sobre-temperatura em capacitores.

### 2.5.3 Interharmônicos

São formas de ondas de tensões ou correntes que apresentam componentes de frequência que não são múltiplos inteiros da frequência fundamental com a qual o sistema é suprido e designado a operar (50 ou 60 Hz). Estes podem aparecer como frequências discretas

ou como uma larga faixa espectral e podem ser encontrados em redes de todas as classes de tensões (DUGAN et al., 2003).

As principais fontes de interharmônicos são os conversores de frequência estáticos, cicloconversores, motores de indução e equipamentos como um forno a arco. Sinais de portadora (*carrier*) em linhas de potência também podem ser considerados como interharmônicos.

Atualmente, existe um melhor entendimento das origens e efeitos dos interharmônicos. Eles são geralmente resultantes da conversão de frequência (ex.: 50 para 60 Hz) e não são constantes, ou seja, variam com a carga. Tais correntes interharmônicas podem excitar ressonâncias bastante severas no sistema de potência, pois as frequências de interharmônicos podem variar de forma a coincidirem com frequências naturais do sistema (DUGAN et al., 2003). Eles também podem afetar a transmissão de sinais de portadora em linhas de potência e induzir *flicker* (cintilação) visual no *display* de equipamentos como tubo de raios catódicos.

#### 2.5.4 Notching

*Notching* é um distúrbio periódico de tensão causado pela operação normal de equipamentos de eletrônica de potência quando a corrente é comutada de uma fase para outra.

O *notching* de tensão representa um caso particular de distúrbios que se estabelece entre transitórios e distorções harmônicas. Por ser um fenômeno que ocorre em regime permanente, ele pode ser caracterizado através do espectro harmônico da tensão afetada. Porém, as componentes de frequências associadas ao *notching* podem ser elevadas e talvez não sejam prontamente caracterizadas por equipamentos utilizados para análise de harmônicos (IEEE Std 1159, 1995).

Os conversores trifásicos que produzem corrente contínua são os principais causadores de *notching*. Ele ocorre quando a corrente é comutada de uma fase para outra. Durante este período, existe um curto-circuito momentâneo entre duas fases, levando a tensão se aproximar do valor zero. Este fenômeno é descrito em detalhes em IEEE Std 519-1992.

A Figura 2.11 mostra um exemplo de *notching* manifestado na tensão de um conversor trifásico que produz corrente contínua.

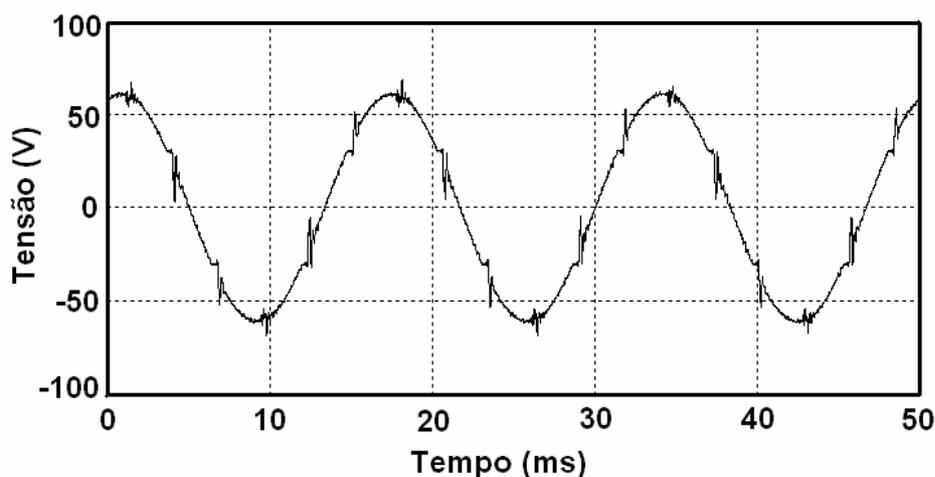


Figura 2.11 – Exemplo de *notching* na tensão causado por um conversor trifásico.

### 2.5.5 Ruídos

Ruído é definido como um sinal elétrico indesejado, contendo uma larga faixa espectral com frequências menores que 200 kHz, superposto à tensão e corrente do sistema de energia nos condutores de fase, ou encontrado nos condutores de neutros ou ainda, nos sinais de linha.

Em sistemas de potência os ruídos podem ser causados por equipamentos eletrônicos, circuitos de controle, equipamentos a arco, cargas com retificadores de estado sólido e fontes chaveadas e, via de regra, estão relacionados com aterramentos impróprios (ARRUDA, 2003). Basicamente o ruído consiste de qualquer distorção indesejada no sinal elétrico que não pode ser classificado como transitório ou distorção harmônica. Eles podem causar distúrbios em equipamentos eletrônicos tais como microcomputadores e controladores programáveis.

## 2.6 Flutuação de tensão

Flutuações na tensão são variações sistemáticas dos valores eficazes de tensão ou uma série de mudanças aleatórias, cujas magnitudes normalmente não excedem faixas de valores compreendidas entre 0,95 e 1,05 p.u. (IEEE Std 1159, 1995) .

Cargas que exibem variações contínuas e rápidas na magnitude da corrente de carga podem causar variações na tensão que são frequentemente referidas como *flicker*. O termo *flicker* é derivado do impacto da flutuação de tensão nas lâmpadas, tal que são perceptivos ao

olho humano. Tecnicamente, flutuação de tensão é um fenômeno eletromagnético enquanto *flicker* é o resultado indesejável da flutuação de tensão em algumas cargas (DUGAN et al, 2003). Geralmente aparecem como uma modulação da frequência fundamental do sistema de energia (similar à modulação de amplitude de um sinal de rádio AM).

Os fornos a arco são as causas mais comuns das flutuações de tensão nos sistemas de transmissão e distribuição. Nesses fornos, as amplitudes das oscilações dependem do estado de fusão do material, bem como do nível de curto-circuito da instalação. As flutuações também são originadas por equipamentos como máquinas de solda, laminadores, elevadores de minas, ferrovias, bem como a partida direta de grandes motores causando diversos efeitos no sistema de energia. A Figura 2.12, da referência (OLESKOVICZ, 2004) ilustra o comportamento do valor eficaz da tensão no barramento supridor de um laminador, durante um período de 5 s.

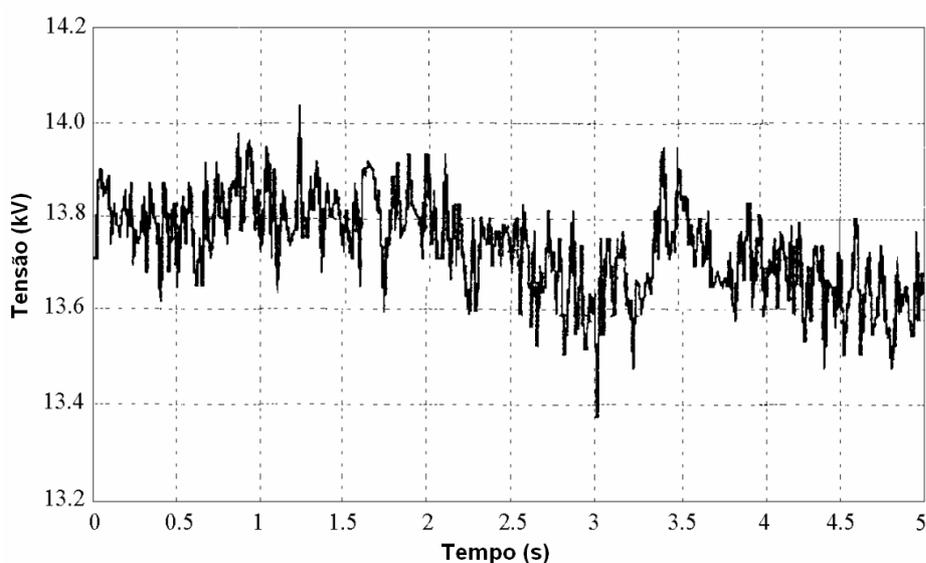


Figura 2.12 – Oscilações de tensão oriundas da operação de um laminador (OLESKOVICZ, 2004).

As flutuações de tensão são definidas pelas suas magnitudes expressas como um percentual da fundamental. O *flicker* é medido com relação à sensibilidade do olho humano. Tipicamente, magnitudes tão baixas quanto 0,5% podem resultar em um *flicker* perceptível em uma lâmpada caso as frequências estejam numa faixa entre 6 e 8 Hz. O fenômeno *flicker* consiste no efeito mais comum provocado pelas oscilações de tensão. Este tema merece especial atenção, uma vez que o desconforto visual associado à perceptibilidade do olho humano às variações da intensidade luminosa é, em toda sua extensão, indesejável.

## 2.7 Variações na frequência do sistema

Variações na frequência de um sistema elétrico são definidas como desvios no valor nominal da frequência fundamental deste sistema (50 ou 60 Hz).

A frequência do sistema de potência está diretamente relacionada à velocidade de rotação dos geradores que suprem o sistema. Há estreitas variações na frequência com o balanço dinâmico entre cargas e mudanças na geração. A amplitude da variação e sua duração dependem das características da carga e da resposta do sistema de controle de geração às alterações na carga.

Variações na frequência que ultrapassam os limites para a operação em regime permanente podem ser causadas por faltas no sistema de transmissão, desconexão de um grande bloco de carga ou pela saída de operação de uma grande fonte de geração.

Nos sistemas modernos interconectados de energia, variações significantes de frequência são raras. Variações consideráveis e frequentes podem mais comumente ocorrer para cargas que são supridas por geradores de sistemas isolados das concessionárias. Em sistemas isolados, como é o caso da geração própria nas indústrias, na eventualidade de um distúrbio, a magnitude e o tempo de permanência das máquinas operando fora da velocidade, resulta em desvios da frequência em proporções mais significativas.

## 2.8 Considerações finais

Os problemas na qualidade da energia elétrica englobam uma extensa gama de diferentes fenômenos sendo que a maioria dos quais foi descrita neste capítulo. De acordo com o que foi apresentado, cada um desses fenômenos pode ter uma variedade de causas e também de soluções que podem ser utilizadas para melhorar a qualidade da energia e a performance de equipamentos. Algumas consequências da degradação da energia elétrica provocadas pelos distúrbios também foram apresentadas, pois quando se trata de medições de distúrbios, é importante saber, ao mesmo tempo, os impactos das variações da qualidade da energia de forma que os problemas possam ser relacionados com as possíveis causas.

### 3 A TRANSFORMADA WAVELET

Historicamente, o conceito de “*wavelets*” começou a aparecer mais frequentemente somente no início da década de 80. Este novo conceito pode ser visto como uma síntese de várias idéias originadas de diferentes campos incluindo matemática, física, ciência da computação e engenharia (DEBNATH, 2002). Uma das principais razões da descoberta das *wavelets* e da transformada *wavelet* é que a análise através da transformada de Fourier (TF) não contém a informação de localização no tempo dos sinais. Portanto, a TF não poderia ser utilizada para analisar sinais no domínio do tempo e da frequência simultaneamente.

A primeira menção de *wavelets* apareceu no apêndice de A. Haar, em 1909 (LIMA, 2003). Uma das propriedades das *wavelets* de Haar era que as mesmas possuíam suportes compactos; que por outro lado não eram continuamente diferenciáveis, o que de certa forma limitava a sua aplicabilidade. As *wavelets* de Haar ficaram no anonimato por muitos anos e, por um período muito longo, elas continuaram a ser a única base ortonormal para as *wavelets* conhecidas.

Em 1982, Jean Morlet, surgiu com uma alternativa para a transformada de Fourier de Tempo Curto (*Short Time Fourier Transformation*), disponibilizando uma nova ferramenta matemática para a análise de ondas sísmicas. Na análise de Morlet, os sinais consistiam de diferentes características no tempo e na frequência, sendo que as componentes de alta frequência teriam um menor espaço de tempo do que as componentes de baixa frequência. Para se obter uma melhora na resolução dos transitórios de altas frequências como também, na resolução de frequência para as componentes de baixas frequências, Morlet introduziu primeiramente a idéia de *wavelets* como uma família de funções construídas através de translações e dilatações de uma única função chamada de “*wavelet mãe*” (DAUBECHIES, 1996), para a análise de sinais não-estacionários.

Em 1985, Stephane Mallat proporcionou às *wavelets* um grande impulso através de seu trabalho em processamento digital de imagens e, inspirado nos resultados de Mallat, Y. Meyer construiu a primeira *wavelet* não-trivial (suave). Ao contrario das *wavelets* de Haar, as *wavelets* de Meyer são continuamente diferenciáveis; contudo, elas não possuem suportes compactos. Poucos anos mais tarde, Ingrid Daubechies usou os trabalhos de Mallat para construir um conjunto de bases ortonormais de *wavelets* suaves, com suportes compactos (LIMA, 2003). Os trabalhos de Daubechies são os alicerces das aplicações atuais de *wavelets*.

De forma geral as *wavelets* são definidas por:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right), \quad a, b \in \mathfrak{R}, \quad a \neq 0, \quad (3.1)$$

onde  $a$  representa um parâmetro de dilatação que mede o grau de compressão ou escala e  $b$  é um parâmetro de translação que determina a localização da *wavelet* no tempo. Se  $|a| < 1$ , a *wavelet*  $\psi_{a,b}(t)$  é uma versão comprimida (menor suporte no domínio do tempo) da *wavelet* mãe  $\psi(t)$  e corresponde às altas frequências. Por outro lado, quando  $|a| > 1$ ,  $\psi_{a,b}(t)$  tem um maior espaço de tempo do que  $\psi(t)$  e corresponde às baixas frequências. Portanto, as *wavelets* têm larguras e tempos adaptados às suas frequências (DEBNATH, 2002).

Nesta seção é visto duas versões da transformada *wavelet* (TW), uma contínua e outra discreta. A Transformada *Wavelet* Contínua (TWC) faz o mapeamento de uma função de uma variável contínua em uma função de duas variáveis contínuas. Já a Transformada *Wavelet* Discreta (TWD) decompõe um sinal discreto em diferentes níveis de resolução.

### 3.1 Transformada *wavelet* contínua

A Transformada de Fourier de Tempo Curto (STFT) faz o mapeamento de um sinal unidimensional em duas dimensões: tempo e frequência. No entanto, a resolução das informações obtidas através da STFT é limitada, pois esta utiliza uma “janela” de dados fixa, isto é, o conteúdo das informações do sinal é amostrado em um intervalo fixo de seu espaço de domínio, Figura 3.1 (a). Deste modo, visando solucionar o problema da resolução, a transformada *wavelet* foi desenvolvida como uma alternativa à STFT, apresentando uma técnica de “janelamento” variável. Esta técnica com *wavelets* é feita similarmente à análise com STFT, no que diz respeito à multiplicação do sinal por uma função, que neste caso, será a *wavelet* e não mais uma “janela”, como na STFT (OLIVEIRA, 2007). Portanto, a TW permite o uso de uma janela de tempo maior para analisar as informações de baixa frequência e uma pequena janela para informações de alta frequência (MISITI et al., 2008), como mostra a Figura 3.1(b).

A Transformada *Wavelet* Contínua é similar a Transformada de Fourier (TF) no sentido que ela é baseada em uma única função  $\psi(t)$  e esta função é escalonada, mas, ao contrário da TF, esta função também é deslocada gerando uma família de funções  $\psi_{a,b}(t)$  com dois parâmetros definidos em (3.1).

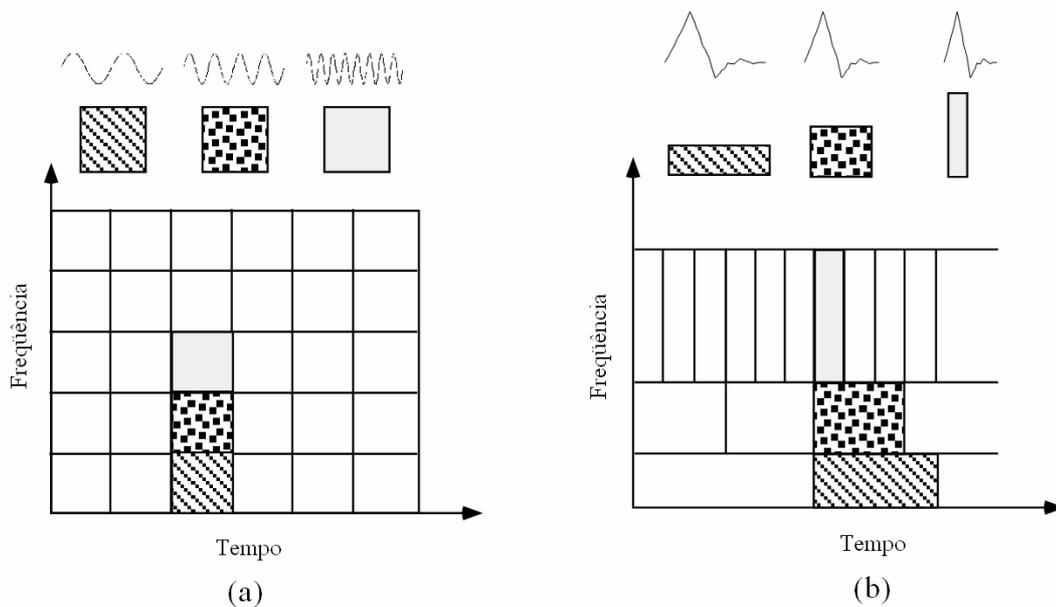


Figura 3.1 – Resolução do plano tempo - frequência pela análise. (a) Transformada de Gabor (STFT); (b) Transformada Wavelet (DAUBECHIES, 1996).

Condições para que  $\psi(t)$  seja uma *wavelet* mãe é que esta deve possuir média zero, decair rapidamente a zero e pertencer ao espaço que contenha todas as funções com energia finita, ou seja,  $\psi(t) \in L^2(\mathfrak{R})$ , desta forma a função  $\psi_{a,b}(t) \in L^2(\mathfrak{R})$ . Escolhendo a normalização tal que  $\|\psi_{a,b}(t)\|^2 = \|\psi(t)\|^2$  para todo  $a, b$ , e assumindo  $\|\psi(t)\| = 1$ , a TWC de um sinal  $f(t)$  dado, em relação à *wavelet* mãe  $\psi(t)$ , é definida como (DAUBECHIES, 1992):

$$(TWC)(a,b) := \int_{-\infty}^{\infty} f(t) \overline{\psi_{a,b}(t)} dt = \langle f(t), \psi_{a,b}(t) \rangle. \quad (3.2)$$

A equação (3.2) mostra que o sinal de uma dimensão  $f(t)$  é mapeado em uma nova função em um espaço bidimensional em escala  $a$  e translação  $b$  pela TW. O grupo de coeficientes  $TWC(a,b)$  associados com um sinal particular é a representação wavelet do sinal original  $f(t)$  em relação à *wavelet* mãe  $\psi(t)$  como ilustrado na Figura 3.2.

A idéia principal da transformada *wavelet* é que ela é uma transformada pontual e proporcional à escala. Ela analisa o sinal em escalas diferentes e se desloca analisando cada trecho do sinal. O parâmetro translação se relaciona com a localização da “janela”. Analisa-se o sinal por partes, processando essencialmente o conteúdo que estiver dentro da janela. O escalonamento é o processo de compressão e dilatação do sinal, que pode ser interpretado a grosso modo da seguinte forma: as altas escalas correspondem a uma visão global do sistema,

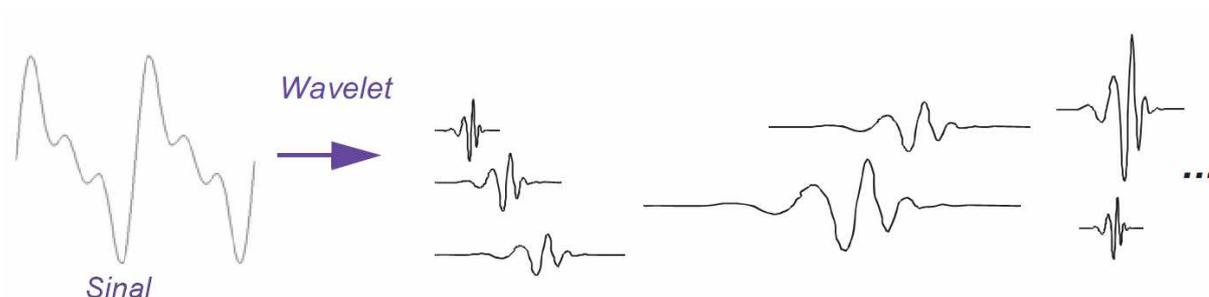


Figura 3.2 – Representação de um sinal em diferentes escalas e posições.

enquanto que as baixas escalas correspondem a uma visão mais detalhada (OLIVEIRA, 2007). Conseqüentemente, é possível analisar componentes de bandas estreitas de frequência de um sinal com um pequeno fator de escala e componentes de bandas largas de frequência com fatores de escala maiores, o que permite captar todas as características de um sinal particular (MISITI et al., 2008).

### 3.1.1 Escalonamento

O escalonamento é o processo de compressão e dilatação do sinal, dessa forma, é introduzido o fator de escala que, freqüentemente, é denotado pela letra  $a$ . O efeito do fator de escala é bem compreensível através de exemplos de senóides mostradas na Figura 3.3.

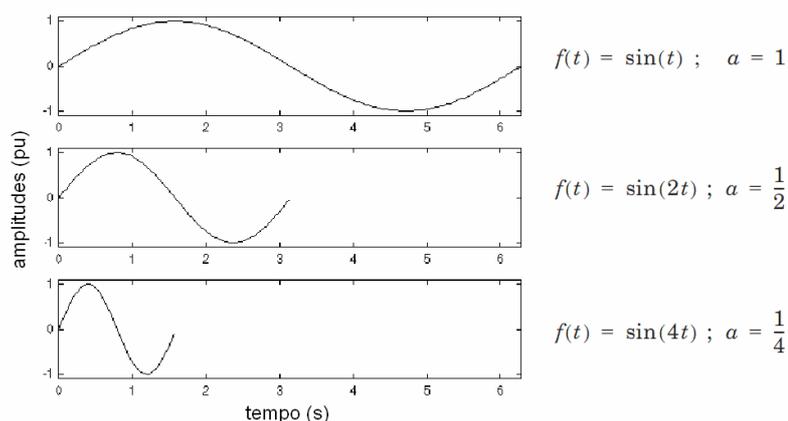


Figura 3.3 – Demonstração do fator de escala em uma função senóide.

O fator de escala trabalha de forma semelhante nas *wavelets*, ou seja, quanto menor o fator de escala, mais “contraída” será a *wavelet*. A Figura 3.4 ilustra o fator de escala atuando com funções *wavelets*.

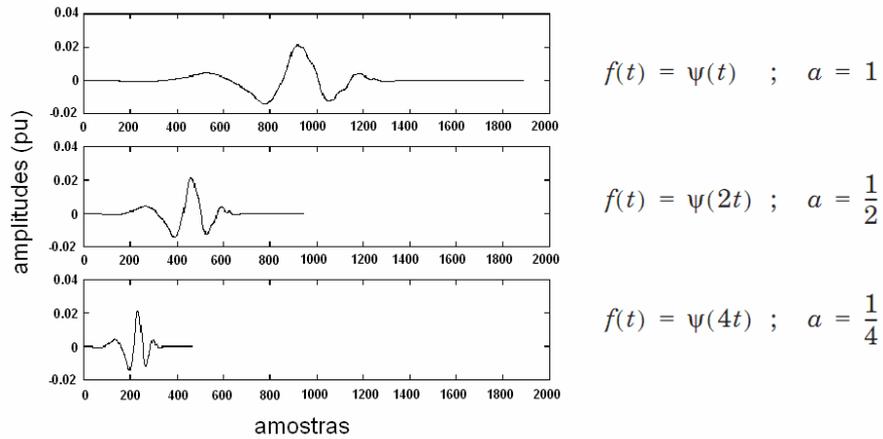


Figura 3.4 – Demonstração do fator de escala atuando em uma função wavelet.

De acordo com a Figura 3.3, fica claro que, para a senóide  $\text{sen}(wt)$ , o fator de escala  $a$  está relacionado (inversamente) com a frequência angular  $w$ . Similarmente é observado na Figura 3.4, com a análise *wavelet*, a escala está relacionada com a frequência do sinal, correspondendo a:

- Baixa escala  $a \rightarrow$  *wavelet* contraída  $\rightarrow$  detalhes que mudam rapidamente  $\rightarrow$  alta frequência  $w$ .
- Alta escala  $a \rightarrow$  *wavelet* dilatada  $\rightarrow$  detalhes que mudam lentamente  $\rightarrow$  baixa frequência  $w$ .

### 3.1.2 Translação

Transladar uma *wavelet* significa deslocá-la no eixo do tempo, ou seja, atrasá-la ou adiantá-la em relação ao eixo das abscissas. Um exemplo matemático é quando se escreve  $f(t-k)$  como um atraso na função  $f(t)$  de um fator  $k$ , com  $k$  constante, como pode ser visto na Figura 3.5.

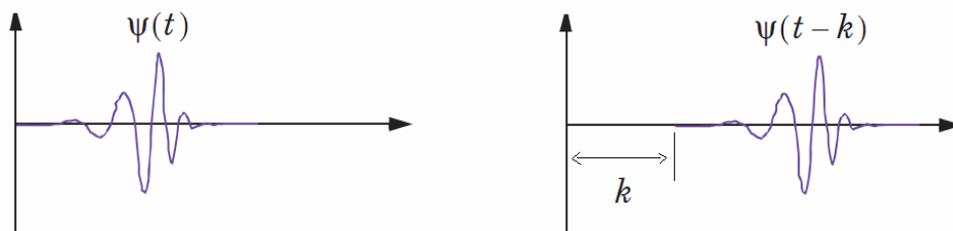


Figura 3.5 – Translação de uma função *wavelet*: (a) Função *wavelet*  $\psi(t)$ ; (b) Função *wavelet* transladada  $\psi(t-k)$ .

### 3.2 Transformada *wavelet* discreta

Tomando-se como base a seção anterior, foi declarado que a transformada *wavelet* contínua é uma representação de uma função em dois parâmetros. Em muitas aplicações, especialmente em processamento de sinais, os dados são representados por um número finito de valores, portanto é importante e útil considerar as versões discretas da transformada *wavelet* (3.2). Do ponto de vista matemático, uma representação contínua de uma função de dois parâmetros contínuos  $a$ ,  $b$  em (3.2) pode ser convertida em uma representação discreta assumindo que  $a$  e  $b$  tenham somente valores inteiros. Inicialmente, isso é feito fixando duas constantes positivas  $a_0$  e  $b_0$ , e definindo (DEBNATH, 2002):

$$\psi_{m,n}(t) = a_0^{-m/2} \psi(a_0^{-m}t - nb_0), \quad (3.3)$$

onde ambos  $m$  e  $n \in \mathbb{Z}$ . Então, para  $f \in L^2(\mathfrak{R})$ , calcula-se os coeficientes *wavelet* discretos  $\langle f(t), \psi_{m,n}(t) \rangle$ . A questão fundamental é se é possível determinar  $f(t)$  completamente pelos seus coeficientes *wavelets* ou sua transformada *wavelet* discreta, que é definida pela equação (3.4).

$$\begin{aligned} (TWD)(m,n) &= \langle f(t), \psi_{m,n}(t) \rangle = \int_{-\infty}^{\infty} f(t) \overline{\psi_{m,n}(t)} . dt \\ &= a_0^{-\frac{m}{2}} \int_{-\infty}^{\infty} f(t) \overline{\psi_{m,n}(a_0^m t - nb_0)} . dt, \end{aligned} \quad (3.4)$$

onde  $f(t)$  e  $\psi(t)$  são contínuas. Nota-se que a transformada *wavelet* discreta (3.4) também pode ser obtida diretamente da versão contínua correspondente (3.2) pela discretização dos parâmetros  $a = a_0^m$  e  $b = nb_0 a_0^m$  ( $m, n$  são inteiros).

A TWD representa uma função através de um conjunto mensurável de coeficientes *wavelet*, os quais correspondem a pontos em uma grade bidimensional de pontos discretos no domínio escala-tempo, indexados por  $m$  e  $n$ . Se o conjunto  $\{\psi_{m,n}(t)\}$  definido por (3.3) é completo em  $L^2(\mathfrak{R})$  para alguma escolha de  $\psi(t)$ ,  $a$  e  $b$ , então, pode-se expressar qualquer  $f(t) \in L^2(\mathfrak{R})$  como a superposição

$$f(t) = \sum_{m,n=-\infty}^{\infty} \langle f(t), \psi_{m,n}(t) \rangle \psi_{m,n}(t). \tag{3.5}$$

Para uma melhor eficiência computacional,  $a_0 = 2$  e  $b_0 = 1$ , são comumente utilizados para que resultados conduzam para uma dilatação binária de  $2^{-m}$  e uma translação diádica de  $n2^m$ . Então, uma discretização prática é  $a = 2^m$  e  $b = n2^m$  em (3.3) para que:

$$\psi_{m,n}(t) = 2^{-\frac{m}{2}} \psi(2^{-m}t - n). \tag{3.6}$$

Com esta escala de tempo e translação, os valores amostrados  $(a,b) = (2^m, n2^m)$  são mostrados na Figura 3.6, que representa um diagrama para a TWD, onde cada ponto corresponde a uma função base  $\psi_{m,n}(t)$  com escala  $2^{-m}$  e translação de tempo de  $n2^{-m}$ .

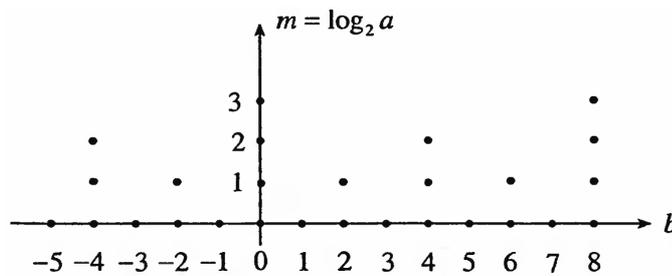


Figura 3.6 – Grade de amostragem diádica ( $2^{-m}$ ) para a transformada *wavelet* discreta.

### 3.3 Análise de multiresolução

O conceito de multiresolução é relacionado com o estudo de sinais ou imagens em diferentes níveis de resolução. A resolução de um sinal é uma descrição qualitativa associada com seu conteúdo de frequência (DEBNATH, 2002).

Em 1986, Stéphane Mallat e Yves Meyer formularam a idéia de análise multiresolução (AMR) no contexto de análise *wavelet*. Esta é uma nova idéia que trata de um formalismo geral para construção de bases ortonormais de *wavelets*. O trabalho de Mallat (1989) foi a principal fonte de muitos desenvolvimentos novos em análises *wavelet* e sua larga variedade de aplicações.

Matematicamente, a idéia fundamental da AMR é representar uma função (ou sinal)  $f(t)$  como um limite de sucessivas aproximações, cada qual sendo uma versão melhor da função  $f(t)$ . Estas sucessivas aproximações correspondem a diferentes níveis de resolução.

Assim, a AMR é um método formal para construir bases *wavelets* ortogonais usando um conjunto definido de regras e procedimentos. A característica chave desta análise é descrever matematicamente o processo que estuda sinais ou imagens em diferentes escalas. O princípio básico da AMR trata com a decomposição de um espaço de função inteiro em subespaços individuais  $V_m \subset V_{m+1}$  é de forma que o espaço  $V_{m+1}$  consiste de todas as funções re-escaladas em  $V_m$ . Isto significa que a decomposição de cada função (sinal) em componentes de diferentes escalas ou frequências de forma que uma componente individual da função original  $f(t)$  ocorra em cada subespaço. Estas componentes podem descrever versões cada vez mais detalhadas da função original  $f(t)$ .

Uma análise de multiresolução consiste de uma seqüência  $\{V_m : m \in \mathbb{Z}\}$  de subespaços fechados de  $L^2(\mathfrak{R})$  que satisfazem as seguintes condições (DEBNATH, 2002):

$$(i) \dots V_{-2} \subset V_{-1} \subset V_0 \subset V_1 \subset V_2 \dots V_m \subset V_{m+1}.$$

$$(ii) \overline{\bigcup_{m=-\infty}^{\infty} V_m} = L^2(\mathfrak{R}).$$

$$(iii) \bigcap_{-\infty}^{\infty} V_m = \{0\}.$$

$$(iv) f(t) \in V_m \text{ se e somente se } f(2t) \in V_{m+1} \text{ para todo } m \in \mathbb{Z}.$$

$$(v) \text{ existe uma função } \phi(t) \in V_0 \text{ tal que } \{\phi_{0,n}(t) = \phi(t-n), n \in \mathbb{Z}\} \text{ é uma base ortonormal para } V_0.$$

A função  $\phi(t)$  é chamada de *função escala*. Se  $\{V_m\}$  é uma multiresolução de  $L^2(\mathfrak{R})$  e se  $V_0$  é um subespaço fechado gerado por translações de uma simples função  $\phi(t)$ , então se pode dizer que  $\phi(t)$  gera uma análise multiresolução. Sendo  $\phi_{0,n}(t) \in V_0$  para todo  $n \in \mathbb{Z}$ , segue de (iv) que

$$\phi_{m,n}(t) = 2^{m/2} \phi(2^m t - n), m \in \mathbb{Z} \quad (3.7)$$

é uma base ortonormal para  $V_m$ .

Repetindo a aplicação da condição (iv) que implica que  $f(t) \in V_m$  se e somente se  $f(2^k t) \in V_{m+k}$  para todo  $f(2t) \in V_{m+1}$   $m, k \in \mathbb{Z}$ . Em outras palavras,  $f(t) \in V_m$  se e somente se  $f(2^{-m} t) \in V_0$  para todo  $m \in \mathbb{Z}$ . Isto mostra que funções em  $V_m$  são obtidas a partir de  $V_0$  por

um escalonamento  $2^{-m}$ . Se a escala  $m=0$  está associada com  $V_0$ , então a escala  $2^{-m}$  está associada com  $V_m$ . Portanto, subespaços  $V_m$  são versões escaladas de um espaço central  $V_0$ .

### 3.3.1 Equação de dilatação

Considerando como espaço de referência  $V_0 \subset V_1$ , a função escala  $\phi(t)$  que forma uma base para  $V_0$  está contida também em  $V_1$ , ou seja,  $\phi(t) \in V_1$  e  $\phi_{1,n}(t) = \sqrt{2}\phi(2t-n)$  é uma base ortonormal para  $V_1$ , assim existe uma seqüência  $\{h(n)\}$  tal que  $\phi(t)$  pode ser expressa da seguinte forma:

$$\phi(t) = \sqrt{2} \sum_{n=-\infty}^{\infty} h(n)\phi(2t-n) \quad n \in \mathbb{Z}. \quad (3.8)$$

Esta é a principal equação da AMR e é chamada de *equação de dilatação*, também referida como equação de refinamento. Ela tem solução única de forma que os coeficientes  $h(n)$  podem ser usados para determinar univocamente a função de escala  $\phi(t)$ . Os coeficientes  $h(n)$  são uma seqüência real ou complexa de números denominados de “coeficientes do filtro passa-baixa”, ou coeficientes do filtro de escala (OLIVEIRA, 2007).

### 3.3.2 Multiresolução e wavelets

Importantes características de muitos sinais são melhores descritos ou parametrizados, não pelo uso de funções  $\phi(t)$ , mas pela definição de um conjunto de funções  $\psi(t)$  ligeiramente diferentes. Estas funções geram espaços complementares àqueles expandidos por funções escalas. Estas funções são chamadas *funções wavelets* (DEBNATH, 2002).

A real importância da AMR cai no simples fato de construir uma base ortonormal para  $L^2(\mathfrak{R})$ . Assumindo que  $\{V_m\}$  é uma AMR, desde que  $V_m \subset V_{m+1}$ , que é um subespaço  $W_m \in L^2(\mathfrak{R})$ , chamados de *espaços wavelets*, como o complemento ortogonal de  $V_m$  no espaço  $V_{m+1}$  para todo  $m \in \mathbb{Z}$ . Assim, tem-se (3.9).

$$\begin{aligned}
V_{m+1} &= V_m \oplus W_m \\
&= (V_{m-1} \oplus W_{m-1}) \oplus W_m \\
&= V_0 \oplus W_0 \oplus W_1 \oplus \dots \oplus W_m \\
&= V_0 \oplus \left( \bigoplus_{m=0}^m W_m \right)
\end{aligned} \tag{3.9}$$

Sendo  $V_m \perp W_m$ , e  $W_m \perp W_{m'}$  para  $m \neq m'$ . O símbolo  $\oplus$  enfatiza a soma ortogonal. Os espaços *wavelets*  $W_m$  são formados por detalhes do sinal na escala  $V_m$ .

Da condição (ii), levando o limite como  $m \rightarrow \infty$ , se obtém  $V_0 \oplus \left( \bigoplus_{m=0}^m W_m \right) = L^2(\mathfrak{R})$ . Da mesma forma para a condição (iii), tem-se que  $V_{-m} = \{0\}$ . Conseqüentemente, todo o espaço  $L^2(\mathfrak{R})$  pode ser obtido unicamente numa soma de espaços ortogonais,

$$\bigoplus_{m=-\infty}^{\infty} W_m = L^2(\mathfrak{R}). \tag{3.10}$$

Seguem das condições (i)-(v), que os espaços  $W_m$  são versões escalonadas de  $W_0$  e, para  $f(t) \in L^2(\mathfrak{R})$ ,

$$f(t) \in W_m \Leftrightarrow f(2^{-m}t) \in W_0 \quad \text{para todo } m \in \mathbb{Z}, \tag{3.11}$$

sendo que esses espaços possuem invariância aos deslocamentos  $n \in \mathbb{Z}$ , ou seja,  $f(t) \in W_m$  se e somente se  $f(t-n) \in W_0$ . Além disso, se existe uma função (*wavelet mãe*)  $\psi(t)$  tal que  $\psi_{0,n}(t) = \psi(t-n)$  constitui uma base ortogonal para  $W_0$ , segue de (3.11) que

$$\psi_{m,n}(t) = 2^{m/2} \psi(2^m t - n), \quad \text{para } n \in \mathbb{Z} \tag{3.12}$$

constitui uma base ortonormal para  $W_m$ . Portanto, a família  $\psi_{m,n}(t)$  representa uma base ortonormal para  $L^2(\mathfrak{R})$ .

Uma vez que os espaços *wavelets* residem no espaço de funções escala do índice seguinte, por exemplo,  $W_0 \subset V_1$ , para uma seqüência de coeficientes  $\{g(n)\}$ , estes podem ser representados como uma soma de funções escala da forma

$$\psi(t) = \sqrt{2} \sum_{n=-\infty}^{\infty} g(n) \phi(2t-n), \quad n \in \mathbb{Z}. \tag{3.13}$$

A equação (3.13) fornece o protótipo da função *wavelet* mãe  $\psi(t)$  para uma classe de funções de expansão da forma

$$\psi_{m,n}(t) = 2^{m/2} \psi(2^m t - n), \quad (3.14)$$

onde o termo  $2^m$  é o fator de escala de  $t$ ,  $n$  é o fator de translação, e o fator  $2^{m/2}$  é o fator de normalização da função.

### 3.4 Relação entre filtragem e análise multiresolução

O processo de filtragem apresenta uma forma prática para a realização da técnica AMR. Este processo baseia-se na filtragem de um sinal a ser analisado através de filtros passa-alta e passa-baixa, fornecendo versões do sinal original relativas aos coeficientes de funções *wavelets* e funções escalas, respectivamente.

#### 3.4.1 Filtragem

Para muitos sinais, a parte mais importante são as componentes de baixa frequência, pois elas fornecem características tais como a identidade destes sinais, enquanto que, as componentes de alta frequência, fornecem os detalhes. Por esta razão que, em análises que utilizam *wavelets*, é usual mencionar aproximações e detalhes dos sinais. As aproximações são as componentes de baixa frequência do sinal. Os detalhes são as componentes de alta frequência (MISITI et al., 2008), sendo o processo de filtragem, em seu nível mais básico, é mostrado na Figura 3.7.

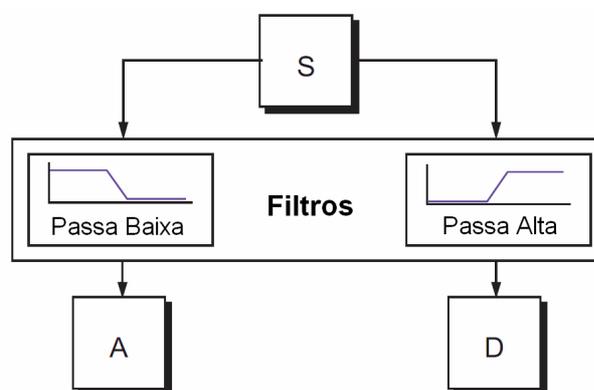


Figura 3.7 – Filtragem de um sinal.

O sinal original,  $S$ , passa através de dois filtros complementares que fornecem como saída dois sinais. Porém, se for utilizado este esquema em um sinal digital real, obtém-se duas vezes mais a quantidade de dados em relação aos dados iniciais. Suponha que o sinal  $S$  consista de 1000 amostras de dados. Sendo assim, as versões de aproximação ( $A$ ) e de detalhes ( $D$ ) do sinal original terão 1000 amostras cada uma, totalizando 2000 amostras, como na Figura 3.8 (a).

Com o intuito de corrigir este problema, foi introduzido um operador que diminui o número de amostras, denominado operador “*downsampling*”, que irá caracterizar uma redução do número de amostras disponibilizadas, como na Figura 3.8 (b). Isto significa considerar dados intercalados, ou seja, levar em conta os dados associados a índices ímpares e rejeitar os dados de índices pares e assim por diante.

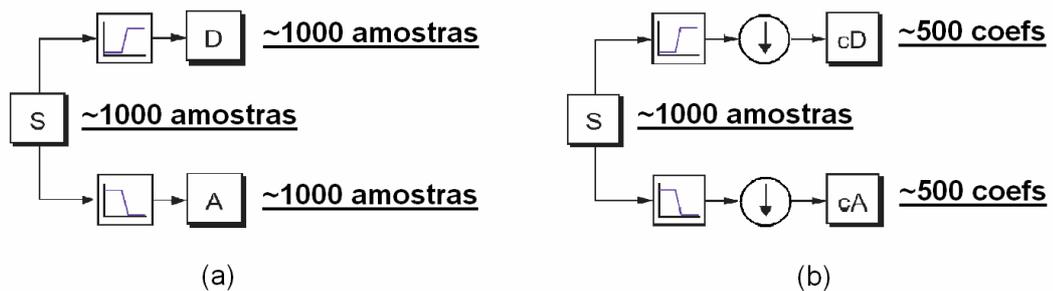


Figura 3.8 – Decomposição de um sinal: (a) sem *downsampling*; (b) com *downsampling*.

A figura 3.8 (a), que mostra o processo de filtragem com o estágio de diminuição do número de amostras, produz os coeficientes  $cD$  e  $cA$  da TWD. Para se obter uma melhor visualização deste processo, é apresentado um exemplo, na Figura 3.9, com o desenvolvimento da TWD de um sinal. O sinal utilizado é uma senóide com ruído de alta frequência.

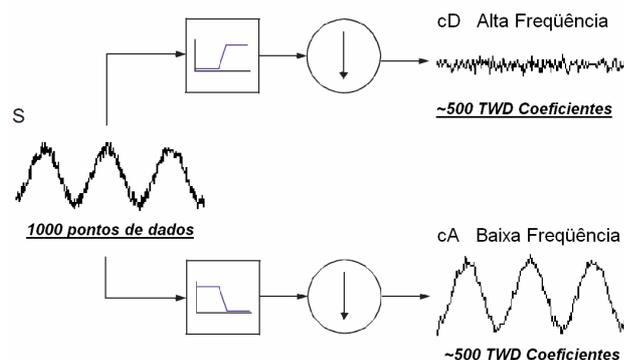


Figura 3.9 – Exemplo de filtragem com *downsampling* de um sinal senoidal ruidoso.

Nota-se que o coeficiente de detalhe  $cD$ , Figura 3.9, consiste principalmente do ruído de alta frequência, enquanto que os coeficientes  $cA$  contém uma quantidade menor de ruído quando comparado ao sinal original.

### 3.4.2 Decomposição em múltiplos níveis

O processo de decomposição pode ser iterativo, com sucessivas decomposições das aproximações, de modo que um sinal é dividido em outras componentes de resolução menor, como mostrado na Figura 3.10.

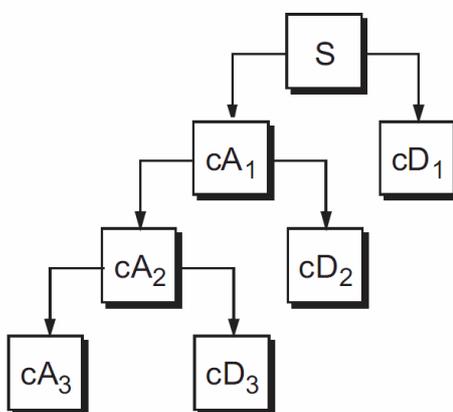


Figura 3.10 – Ilustração do processo sucessivo de decomposição de um sinal em três níveis pela AMR.

Uma vez que o processo é iterativo, na teoria podem-se decompor os sinais indefinidamente. Na realidade, a decomposição pode proceder somente até que o detalhe individual consista em somente uma amostra ou *pixel* para o caso de imagens. Na prática, seleciona-se um número satisfatório de níveis, baseado na natureza do sinal. Para os casos de estudos com sinais elétricos, o número de decomposições é limitado pelo nível de frequência e pela quantidade de amostras do sinal a ser analisado.

### 3.4.3 Reconstrução *wavelet*

Foi apresentado anteriormente como a TWD pode ser utilizada para analisar, ou decompor, sinais ou imagens. Uma outra etapa é saber como aquelas componentes podem ser reagrupadas para montar, ou reconstruir o sinal original, sem perder informações. Este

processo é chamado reconstrução ou síntese. Esta manipulação matemática que efetua a síntese é chamada Transformada *Wavelet* Discreta Inversa (TWDI).

Para sintetizar um sinal, o reconstruímos a partir dos coeficientes *wavelet*, como ilustra a Figura 3.11.

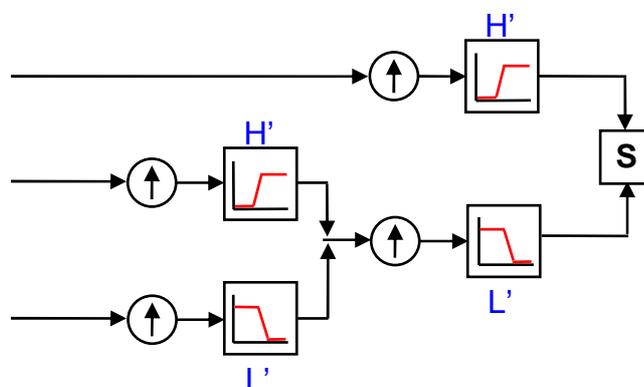


Figura 3.11 – Reconstrução de um sinal filtrado.

Como a análise *wavelet* envolve filtragem e diminuição do número de amostras (*downsampling*), a reconstrução *wavelet* consiste em aumentar o número de amostras (*upsampling*) e filtragem. *Upsampling* é o processo de alongar uma componente do sinal inserindo zeros entre amostras, como pode ser visto na figura 3.12.

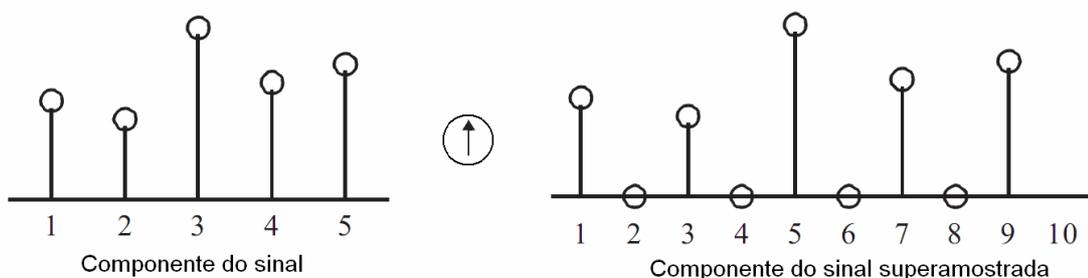


Figura 3.12 – processo de aumento do número de amostras de um sinal.

#### 3.4.4 Filtros de reconstrução

A parte da filtragem referente ao processo de reconstrução também merece algumas discussões, porque a escolha dos filtros é crucial para alcançar uma perfeita reconstrução do sinal original.

O processo de diminuição do número de amostras do sinal realizado na fase de decomposição, introduziu distorções de *aliasing*, causados por descontinuidade do sinal.

Portanto, se mostra que por uma escolha correta dos filtros para as fases de decomposição e reconstrução, é possível cancelar os efeitos de *aliasing*. Uma discussão técnica de como projetar estes filtros (Figura 3.13) está disponível em Strang, G. e Nguyen, T. (1996).

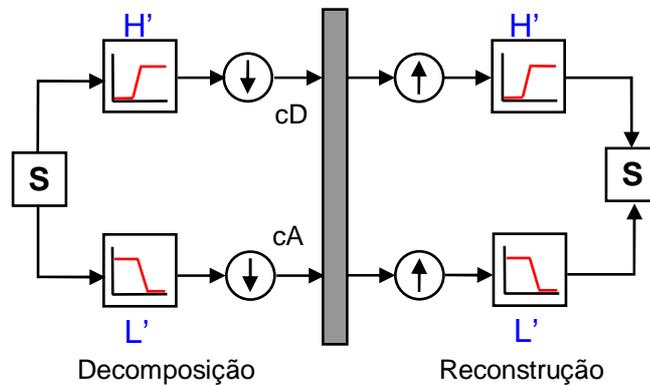


Figura 3.13 – Processo de decomposição e reconstrução de um sinal.

### 3.4.5 Reconstruindo as aproximações e os detalhes

Foi visto que é possível uma reconstrução do sinal original a partir dos seus coeficientes de aproximações e detalhes. Nesta seção, será visto que também é possível reconstruir as aproximações e detalhes em si, a partir dos seus vetores de coeficientes. Como exemplo, mostra-se como reconstruir o primeiro nível de aproximação  $A_1$ , do vetor de coeficientes  $cA_1$  (MISITI et al., 2008).

O vetor de coeficientes  $cA_1$  passa pelo mesmo processo usado para reconstruir o sinal original. No entanto, ao invés de combiná-los com o nível um de detalhes ( $cD_1$ ), alimenta-se com um vetor de zeros no lugar dos detalhes, como mostrado na Figura 3.14.

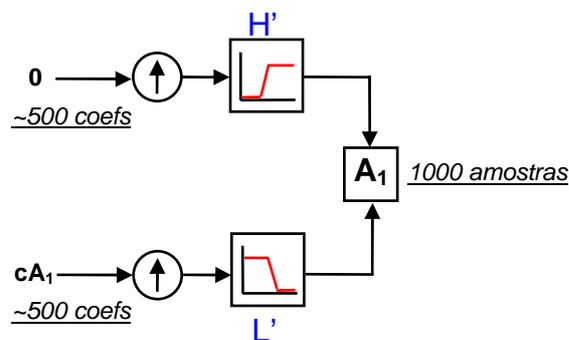


Figura 3.14 – Processo de reconstrução da aproximação  $A_1$  alimentado com vetor de zeros.

Este processo produz a aproximação  $A_1$  reconstruída, que possui o mesmo tamanho do sinal original  $S$ , sendo uma aproximação real.

Similarmente, pode-se reconstruir o primeiro nível de detalhe  $D_1$ , usando um processo análogo, como mostra a Figura 3.15, com a utilização do vetor de coeficientes de detalhes.

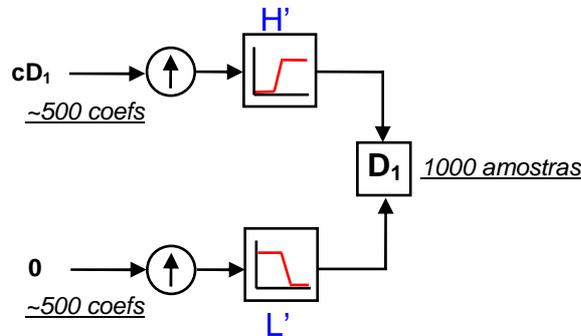


Figura 3.15 – Reconstrução do primeiro nível de detalhe do sinal com inserção do vetor de zeros.

Os detalhes e aproximações reconstruídos são verdadeiramente constituintes dos sinais originais. De fato, encontra-se isto quando se combina  $A_1 + D_1 = S$ .

Note que os coeficientes  $cA_1$  e  $cD_1$ , por serem produzidos pela diminuição do número de amostras e suas dimensões serem somente a metade da dimensão do sinal original, não podem ser combinados diretamente para reproduzir o sinal original. É necessário reconstruir as aproximações e detalhes antes de combiná-los.

Estendendo esta técnica para componentes de uma análise multinível, encontram-se relações similares para todo o sinal reconstruído (Figura 3.16) (MISITI et al., 2008).

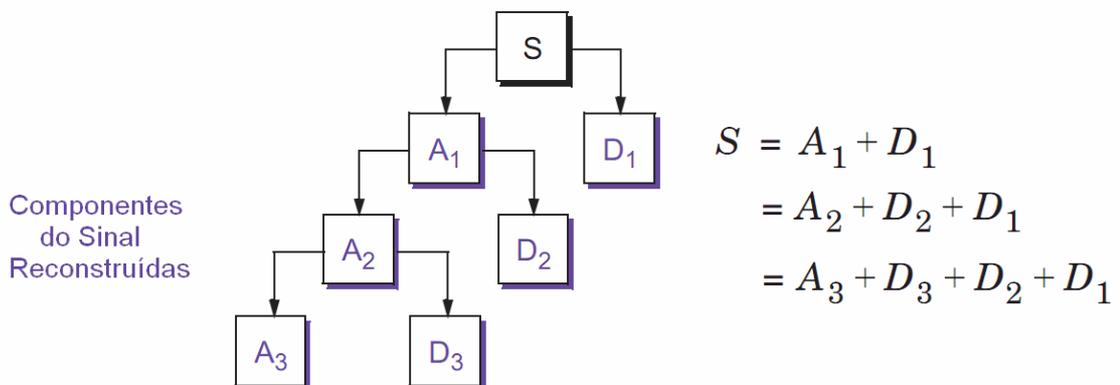


Figura 3.16 – Diferentes formas para se reconstruir o sinal original a partir de seus coeficientes.

### 3.4.6 Freqüências em cada nível de decomposição

A AMR apresenta diversas faixas de frequências de acordo com o nível de decomposição realizado de uma maneira geral, pode-se obter o conteúdo de frequência de cada nível de decomposição de forma genérica para qualquer valor de taxa amostral. De acordo com o teorema de *Nyquist*, a metade da frequência de amostragem corresponde ao limite máximo da frequência do sinal que pode ser reproduzido. Desta forma, se pode garantir apenas até  $(\text{frequência de amostragem})/2$  Hz do sinal de entrada. Assim, a máxima frequência representada pelos coeficientes em cada nível de resolução é dada por:

$$freq_{Nivel} = \frac{freq_s}{2^{Nivel}}, \quad (3.15)$$

onde  $freq_s$  é a frequência de amostragem.

Neste estudo foram considerados sinais de tensão com frequência de amostragem de 15360 Hz, o que corresponde a 256 amostras por ciclo. Desta forma, é possível garantir até 7680 Hz do sinal de entrada. Tomando esta informação como base, para um exemplo de decomposição de um sinal em 4 níveis, as frequências em cada nível apresentam-se da seguinte forma (Figura 3.17):

- Aproximação 1,  $A_1$ : [0 – 3840] Hz, o que corresponde à metade inferior da frequência do sinal de entrada;
- Detalhe 1,  $D_1$ : [3840 – 7680] Hz, o que corresponde à metade superior da frequência do sinal de entrada;
- Aproximação 2,  $A_2$ : [0 – 1920] Hz, que corresponde à metade inferior da frequência do sinal de aproximação anterior,  $A_1$ ;
- Detalhe 2,  $D_2$ : [1920 – 3840] Hz, que corresponde à metade superior da frequência do sinal de aproximação anterior,  $A_1$ ;
- Aproximação 3,  $A_3$ : [0 – 960] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 2 –  $A_2$ ;
- Detalhe 3,  $D_3$ : [960 – 1920] Hz, que corresponde à metade superior da frequência do sinal de aproximação 2 –  $A_2$ ;
- Aproximação 4,  $A_4$ : [0 – 480] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 3 –  $A_3$ ;
- Detalhe 4,  $D_4$ : [480 – 960] Hz, que corresponde à metade superior da frequência do sinal de aproximação 3 –  $A_3$ ;

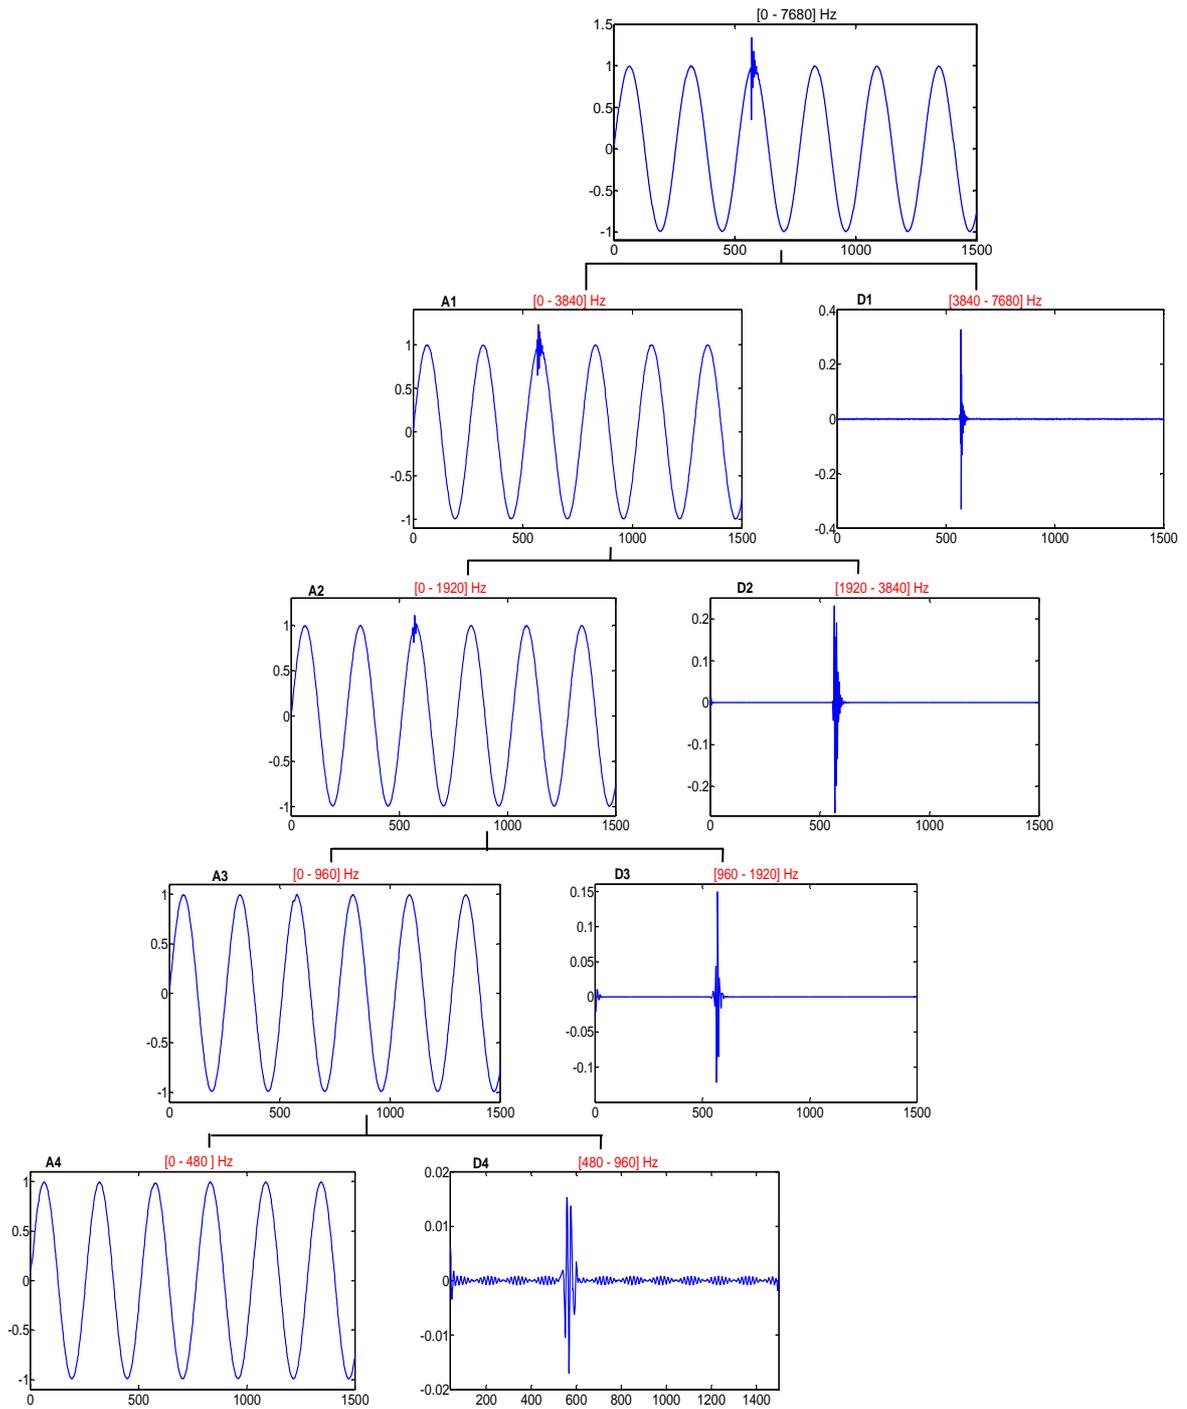


Figura 3.17 – Amplitude *versus* tempo da AMR de um sinal amostrado a 15360 Hz, com detalhamento das frequências.

E assim, continuando a decomposição até 9 níveis, que é a proposta deste trabalho, tem-se:

→ Aproximação 5,  $A_5$ : [0 – 240] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 4 –  $A_4$ ;

- Detalhe 5,  $D_5$ : [240 – 480] Hz, que corresponde à metade superior da frequência do sinal de aproximação 4 –  $A_4$ ;
- Aproximação 6,  $A_6$ : [0 – 120] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 5 –  $A_5$ ;
- Detalhe 6,  $D_6$ : [120 – 240] Hz, que corresponde à metade superior da frequência do sinal de aproximação 5 –  $A_5$ ;
- Aproximação 7,  $A_7$ : [0 – 60] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 6 –  $A_6$ ;
- Detalhe 7,  $D_7$ : [60 – 120] Hz, que corresponde à metade superior da frequência do sinal de aproximação 6 –  $A_6$ ;
- Aproximação 8,  $A_8$ : [0 – 30] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 7 –  $A_7$ ;
- Detalhe 8,  $D_8$ : [30 – 60] Hz, que corresponde à metade superior da frequência do sinal de aproximação 7 –  $A_7$ ;
- Aproximação 9,  $A_9$ : [0 – 15] Hz, que corresponde à metade inferior da frequência do sinal de aproximação 8 –  $A_8$ ;
- Detalhe 9,  $D_9$ : [15 – 30] Hz, que corresponde à metade superior da frequência do sinal de aproximação 8 –  $A_8$ .

#### 4.5 Considerações finais

Neste capítulo, foram apresentadas as fundamentações teóricas da TW. Também foi visto que a TW provê informações sobre o conteúdo de frequência de sinais similarmente a transformada de *Fourier* (TF). Porém, ao contrário da TF, a TW é capaz de focalizar pequenos intervalos de tempo para conteúdos de alta frequência e em longos intervalos de tempo para conteúdos de baixa frequência. Pode-se dizer que a análise por *wavelet* transpõe as limitações dos métodos de *Fourier* pelo emprego de funções de análise que são localizáveis no tempo e na frequência. Estas funções por possuírem suas energias concentradas (finitas) no tempo, tornam a TW uma desejável ferramenta para a análise de fenômenos transitórios de alta frequência (impulsos e oscilações localizadas), principalmente na presença da componente fundamental. Por isso, ela é altamente apropriada e bem aceita para uma ampla faixa de sinais não estacionários e que podem conter ambas as componentes senoidais e de impulso, como é típico nos transitórios de sistemas de potência.

## 4 APLICAÇÕES DA TRANSFORMADA *WAVELET* EM QUALIDADE DE ENERGIA

Neste capítulo são destacados alguns artigos científicos que utilizaram a transformada *wavelet* em suas metodologias para analisar fenômenos e distúrbios relacionados à qualidade da energia elétrica.

Santoso et al. (1994) buscaram uma nova abordagem para detectar e localizar distúrbios relacionados à qualidade da energia. Ao contrário de muitos trabalhos da época, cujas detecções eram realizadas no domínio do tempo, eles propuseram uma metodologia para a detecção e localização de distúrbios utilizando a transformada *wavelet* ortonormal para analisar sinais no domínio do tempo e frequência. Para isso, eles dividiram os eventos (distúrbios) em duas categorias: transitórios rápidos e transitórios lentos. Para os transitórios rápidos as formas de ondas são caracterizadas por pulsos, variações rápidas e abruptas em um pequeno intervalo de tempo. Neste caso, as *wavelets* mães db4 e db6, são as mais adequadas a detecção e localização destes distúrbios devido as mesmas possuírem suportes compactos. A *wavelet* é dita ser de suporte compacto se a maioria da energia desta *wavelet* está restrita a um intervalo finito, ou seja, se a função é zero fora deste intervalo. Neste caso, diz-se que as *wavelets* têm localização espacial. Para o caso de transitórios lentos, as formas de ondas são caracterizadas por mudanças suaves. Segundo os autores, as *wavelets* db4 e db6 não são eficientes em capturar tais distúrbios, pois as mesmas apresentam intervalo de integração pequeno. Por isso as *wavelets* db8 e db10 foram utilizadas, pois seus intervalos de integração são longos o suficiente para captar as transições lentas. Além disso, este método foi utilizado para analisar transitórios, afundamentos de tensão e distorções harmônicas.

Os sinais contendo os distúrbios foram gerados computacionalmente a uma taxa de amostragem de 2,56 kHz. As *wavelet* mães utilizadas foram a db10 e a db4 com uma escala de decomposição. Na análise dos transitórios a db4 foi a que melhor se adequou por apresentar suporte compacto e tempo de integração menor que a db10. Já no caso dos afundamentos de tensão a db10 apresentou melhor resposta, pois o distúrbio é tão lento que a db4 não tem tempo de integração suficiente para perceber a mudança. Nas distorções harmônicas foram adicionadas componentes de ordem inferior a 25ª harmônica em uma onda senoidal pura de 60 Hz, resultando em uma taxa de distorção de 11,49%. Nesta análise foi possível perceber que as *wavelets* detectaram a presença de harmônicos nos sinais, porém não

identificaram e quantificaram os conteúdos harmônicos presentes nele. Na comparação dos resultados, a db10 superou a db4, também no caso de localização de harmônicos.

Em outro trabalho, Santoso et al. (1996), foi apresentado um estudo para detectar, localizar e investigar vários tipos de distúrbios relacionados à qualidade da energia, através do uso da transformada *wavelet* (TW). A proposta era decompor os sinais originais com distúrbios em aproximações e detalhes dos sinais originais. As decomposições foram realizadas utilizando a *análise de multiresolução* (AMR). Para melhor caracterizar os distúrbios, os autores propuseram a utilização do quadrado dos coeficientes da TW. Em qualidade da energia, muitos distúrbios contêm impulsos, transitórios, e ao empregar tal técnica é possível decompor os sinais em coeficientes, o que resulta em uma versão detalhada e uma versão aproximada do sinal original, podendo ser feita em várias escalas. Neste trabalho, ao invés dos autores implementarem um algoritmo para escolher a *wavelet* apropriada para analisar cada tipo de distúrbio, os autores utilizaram apenas uma *wavelet* mãe para analisar todos os tipos de distúrbios. Em AMR, na escala mais baixa, que é a primeira, as *wavelets* são mais localizadas no tempo e oscilam mais rapidamente em um período de tempo pequeno. Conforme as escalas vão aumentando as *wavelets* tornam-se menos localizáveis no tempo e oscilam menos devido a dilatação natural ocorrida na transformação. Como resultado da decomposição em mais escalas, distúrbios com transitórios rápidos e curtos são detectados nas escalas menores, já os distúrbios com transitórios longos e lentos são detectados nas escalas maiores. Assim, os autores estabeleceram este método para detectar distúrbios rápidos e lentos com uma única função *wavelet*, que neste caso a escolhida foi db4 por apresentar suporte compacto. O método foi aplicado para analisar sinais como curtos-circuitos e transitórios, obtidos através de medições. Estes sinais foram decompostos em 4 escalas mostrando as potencialidades da TW em detectar diversos distúrbios ao longo das escalas.

Santoso et al. (2000a) apresentaram uma fundamentação teórica para a classificação de distúrbios utilizando redes neurais. O método de reconhecimento proposto utiliza *wavelets* e um conjunto de múltiplas redes neurais. A idéia básica do classificador é fazer o reconhecimento dos distúrbios no domínio *wavelet* utilizando múltiplas redes neurais. Os resultados das redes neurais são integrados usando um método de tomada de decisão, ou seja, um simples método de votação. A entrada do classificador consiste em um sinal com distúrbio no domínio do tempo. O método consiste em três etapas: a etapa de pré-processamento, a etapa de processamento e a etapa de pós-processamento. Na etapa de pré-processamento o sinal com distúrbio no domínio do tempo passa pela transformada *wavelet* antes de alimentar

as redes neurais. Esta etapa detecta e extrai características dos distúrbios no domínio do tempo e da frequência simultaneamente. As características extraídas ajudam a rede neural a distinguir um distúrbio do outro. A fase de processamento contém um conjunto de múltiplas redes neurais sendo que a entrada dessas redes são os coeficientes *wavelets*. A saída, das redes neurais, é o tipo de distúrbio. No entanto, como existe um conjunto de múltiplas redes, foi utilizada uma etapa de pós-processamento para tomar uma decisão em relação ao tipo de distúrbio com seu respectivo intervalo de confiança. A segunda etapa do trabalho proposto por Santoso et al. (2000b), emprega a aplicação da teoria apresentada no trabalho anterior. Nesta etapa foi avaliada a performance do classificador neural em reconhecer distúrbios. Foram selecionadas seis categorias de distúrbios para a classificação: chaveamento de capacitores rápidos e lentos, senóide de 60 Hz perfeita, transitórios impulsivos, afundamentos de tensão (*sag*) e interrupções momentâneas. Neste método, os sinais enquadrados nas quatro primeiras categorias são classificados no domínio *wavelet* utilizando o método de votação, sendo que os sinais das duas últimas categorias são classificados no domínio do tempo. Utilizando uma taxa de amostragem de 15,360 kHz (256 amostras por ciclo), os resultados do algoritmo comprovaram uma eficiência maior que 90% entre os seis tipos de distúrbios analisados, com um índice de ambigüidade menor que 10%.

Zhu et al. (2004) apresentaram um outro método para a classificação de distúrbios que utiliza uma base de regras *fuzzy* para caracterizar cada tipo de distúrbio. Para extrair as características dos sinais contendo distúrbios, os autores utilizaram o cálculo da distribuição da energia de cada um dos níveis de decomposição *wavelet*. Como visto em trabalhos anteriores, a TW provê uma representação dos sinais tanto no domínio do tempo como da frequência, consistindo na decomposição desses sinais em coeficientes de aproximações e coeficientes de detalhes. Para incrementar a resolução da classificação, as características devem ser extraídas desses coeficientes. Neste caso, os autores consideraram a distribuição da energia dos coeficientes *wavelets* uma representação estável para os diversos tipos de distúrbios. Baseadas nessas distribuições de energia foram geradas bases de regras que discriminam as formas de onda dos diferentes distúrbios. Após a *fuzzificação* e *defuzzificação* os distúrbios apresentados no domínio *wavelet* são mapeados para um conjunto de números reais de uma dimensão que identificam os tipos de distúrbios. Os sinais contendo os distúrbios foram gerados através de simulações computacionais de um sistema de distribuição de uma refinaria, resultando em uma base de dados contendo 507 distúrbios que foram utilizados pra projetar o classificador *fuzzy*. Os distúrbios considerados neste trabalho são: chaveamento de

capacitores de alta e baixa frequência, afundamentos de tensão, transitórios impulsivos, *energização* de transformadores e senóides perfeitas. A *wavelet* mãe utilizada foi a db4 e os sinais foram decompostos em 5 níveis. Para testar o algoritmo foram gerados outros 1106 novos distúrbios e posteriormente foram classificados e, de acordo com os resultados, foram detectados sem nenhum erro.

Chung et al. (2000) apresentaram um algoritmo que utiliza o *hidden Markov models* (HMM) baseado na transformação *wavelet*. Assim como em outros trabalhos a *wavelet* db6 utilizada para extrair características dos distúrbios decompondo os sinais em vários níveis de resolução, sendo os coeficientes utilizados para modelar o HMM. Baseado neste modelo um classificador de máxima verossimilhança foi aplicado para reconhecer 4 tipos de distúrbios considerados, são eles: transitórios como chaveamentos de capacitores rápidos e normais, sinal normal e *notching*. Todos os dados foram obtidos através de medições em uma linha de distribuição que totalizaram 507 sinais a uma taxa de amostragem de 15,36 kHz. Os distúrbios observados foram classificados pela máxima verossimilhança com 95,5% de precisão utilizando uma etapa de pós-processamento.

Em um trabalho posterior, Chung et al. (2002) apresentaram um classificador combinando 2 métodos. O primeiro classifica os distúrbios caracterizados no domínio do tempo utilizando um classificador baseado em regras para classificar distúrbios como afundamento e interrupção de tensão. O segundo método utiliza a TW e é semelhante ao proposto anteriormente que utiliza o HMM e o cálculo da máxima verossimilhança. Na primeira etapa do algoritmo os autores desenvolveram regras gerais para classificar os afundamentos e interrupções. Considerando que as características no domínio do tempo são bem definidas pelo valor eficaz para estes sinais, primeiramente é calculado o valor eficaz do sinal de entrada baseado na frequência fundamental (60 Hz). Quando um afundamento ou uma interrupção ocorre, a frequência fundamental pode variar, portanto é necessário saber exatamente o valor da frequência para calcular o verdadeiro valor eficaz e estabelecer níveis de *threshold* para cada evento. Se o tipo de evento é determinado nesta etapa o procedimento de classificação é interrompido, senão é passado para a próxima etapa, que contém o classificador HMM, para classificar em outros tipos de distúrbios. Este classificador combinado permitiu a classificação de 6 de seis tipos de eventos com 97,9% de acertos e 98,7% utilizando uma etapa de pós-processamento.

Karimi et al. (2000) apresentaram uma proposta para identificar distúrbios de tensão on-line e classificar o tipo de evento que resultou no distúrbio, também fazendo uso da TW. A

detecção dos distúrbios é baseada na simulação de um grande número de faltas e chaveamento de capacitores que ocorrem em um sistema de distribuição usando o software PSCAD/EMTDC. O sistema de classificação consiste em 4 blocos: geração do sinal de erro, análise do sinal de erro com a TW, extração das características e a tomada da decisão. No primeiro bloco ocorre a subtração entre o sinal em regime permanente e o sinal com distúrbio, gerando um sinal de erro através de um filtro adaptativo. O filtro sincroniza a amplitude e a frequência da componente fundamental do sinal de entrada. As distorções do sinal de entrada aparecem no sinal de erro sem nenhum atraso. No segundo bloco, a TW é utilizada para decompor o sinal de erro em diferentes escalas de tempo e frequência. Neste bloco a *wavelet* mãe com suporte compacto utilizada é a *Spline* linear da família Battle-Lamarie. No terceiro bloco o objetivo é identificar assinaturas específicas dos distúrbios no sistema. As energias contidas nas escalas mudam dependendo do tipo de distúrbio. O processo de extração de características se inicia quando o sinal de erro excede um limiar de 10% da tensão nominal. No último bloco, que é o bloco da classificação, é utilizada a função de probabilidade das características e a tomada de decisão é feita pelo critério da Máxima Verossimilhança, com certo grau de precisão. Uma continuação destes estudos foi apresentada por Hossen et al. (2002), onde os autores avaliaram a performance do método aplicando-o em dois sistemas de baixa e média tensão, ou seja, 120 V e 12 kV, respectivamente. Os resultados foram satisfatórios e atenderam as expectativas dos autores.

Kanitpanyacharoen e Premrudeepreechacharn (2004) apresentaram um método de classificação de problemas de qualidade da energia nos sistemas elétricos de potência combinando transformada *wavelet* e redes neurais artificiais (RNA). Este método foi capaz de classificar seis tipos de problemas precisamente, como: transitórios impulsivos, interrupção, afundamento e elevação de tensão, *notching* e distorção harmônica. A transformada *wavelet* é utilizada para detectar e extrair as características das perturbações através da análise de multiresolução (AMR), decompondo os sinais em 12 diferentes níveis de resolução, com a justificativa de que a transformada *wavelet* é sensível a irregularidades dos sinais. Para quantificar a magnitude das variações dentro de um sinal, os autores utilizaram a curva de desvio padrão da análise dos coeficientes *wavelet*. Assim, a extração com a AMR ajuda a distinguir um distúrbio do outro. O desvio padrão foi utilizado para representar os dados em cada nível da resolução. Portanto, para uma melhor análise e para impedir confusões, os autores fazem a subtração entre o desvio padrão de cada nível calculado do sinal com distúrbio e o desvio padrão de cada nível de um sinal senoidal puro, resultando em um delta

desvio padrão. Assim, foi possível identificar as diferenças entre uma curva de desvio padrão de um afundamento e uma curva de desvio padrão de uma elevação. Estas diferenças calculadas para cada distúrbio são as entradas de uma rede neural analítica (ANN) que tem a finalidade de classificar os diferentes eventos. As simulações foram realizadas no software MATLAB<sup>®</sup> e foram escolhidos 200 sinais de cada distúrbio para testar a (ANN). O algoritmo foi capaz de detectar os 6 tipos eventos com uma precisão de 98,9% para sinais sem ruídos e 98,1% para sinais com ruídos.

Chen e Zhu (2007) apresentaram uma revisão do uso da transformada *wavelet* no processamento de dados de qualidade da energia. Os esforços, limitações e desafios no emprego do método são discutidos neste trabalho, levando em consideração as necessidades e expectativas quando se analisa distúrbios. O trabalho inicia com uma aprofundada revisão da teoria da TW e do método da AMR fazendo comparações de tempo e frequências em relação à transformada de Fourier. Em seguida, os autores discutem várias metodologias para a análise de distúrbios que utilizam a TW através de demonstrações e exemplos. Considerações são realizadas contemplando a adoção da transformada *wavelet* nas aplicações em qualidade de energia, ressaltando que a escolha da *wavelet* mãe, a escolha da transformação contínua ou discreta e o número de decomposições são os três critérios mais importantes que podem afetar significativamente a desempenho dos métodos. Para finalizar, os autores apresentaram um novo método combinando transformada *wavelet* e *rank* de correlação como alternativa para identificar transitórios oscilatórios devido ao chaveamento de banco de capacitores. *Rank* de correlação é um tipo de método estatístico não-paramétrico que estima a similaridade entre dois sinais através de seus *ranks*. Nesse trabalho ele é utilizado para estimar a similaridade entre a variação na amplitude transitória e a forma de onda fixa pré-definida. A *wavelet* utilizada foi a db2 devido a sua simplicidade, apresentando resultados satisfatórios para o propósito dos autores.

Gaing (2004) apresentou um classificador para identificar vários distúrbios de qualidade da energia que consiste em duas etapas. A primeira consiste na aplicação da TW utilizando a técnica de AMR, seguido da aplicação do teorema de Parseval para obter a distribuição das energias contidas nos coeficientes *wavelets* extraídos dos sinais distorcidos em diferentes níveis de resolução. Na segunda etapa, uma rede neural probabilística (RNP) foi empregada para classificar os tipos de distúrbios de acordo com a duração e a distribuição de energia ao longo das escalas. Na etapa de extração de características, os autores consideraram os tempos de duração de cada distúrbio para ajudar a rede neural a identificá-los. Em geral,

quando um transitório ocorre, é gerada uma descontinuidade no sinal no início e no fim do evento. Aplicando a TW, é possível perceber essa descontinuidade claramente no primeiro nível de decomposição, pois ocorrem grandes variações nos coeficientes *wavelets* exatamente nos tempos de início e fim dos eventos. Dessa forma os tempos de duração de cada um dos distúrbios considerados puderam ser calculados para inserção na rede neural. O método proposto foi desenvolvido no software MATLAB sendo que os distúrbios como interrupção momentânea, afundamento e elevação de tensão, distorções harmônicas e *flicker*, foram decompostos em 13 níveis de resolução utilizando a *wavelet* db4. Os resultados experimentais mostraram a eficiência do classificador em identificar distúrbios com uma precisão de 90% para os seis tipos considerados.

Abdel-Galil et al. (2005) propuseram um classificador utilizando o HMM combinado com quantização vetorial (QV) computacionalmente eficiente para a classificação de fenômenos lentos e rápidos. Os sinais de tensão são observados por uma janela móvel ou através da TW ou pela transformada de Fourier. Em seguida é aplicada a QV para transformar as observações contínuas em uma seqüência de observações discretas que serão as entradas dos HMMs. No estágio de treinamento foi construído um HMM para cada fenômeno considerado. No estágio de classificação os modelos de HMM produziram uma saída contendo um *rank* dos mais prováveis distúrbios associados com o sinal de entrada. Para selecionar o tipo de distúrbio foi utilizado o algoritmo de máxima verossimilhança. Os sinais foram obtidos através de simulações em MATLAB, onde foram geradas 6 categorias: senóide sem distúrbio, afundamento e elevação de tensão, harmônicos, transitórios oscilatórios e *flicker*. A freqüência de amostragem utilizada foi 256 amostras/ciclo, que permitiu a detecção de freqüências próximas a 4 kHz. Foram analisados 200 exemplos de cada distúrbio para treinamento e outros 200 de cada distúrbio para testes. Nas simulações, para a aplicação da QV, foram testados diferentes tamanhos de *codebook*, 8, 16, 32 e 64. Dessa forma, os autores mostraram que ocorria um aumento na resolução de classificação conforme se aumentava o tamanho do *codebook*, mas observaram também que o valor saturou em 64, ou seja, um aumento maior não resultaria na melhora da resolução de classificação. Foram realizados testes utilizando as duas ferramentas de extração de características, a TW e a transformada de Fourier, obtendo uma resolução média de 96,5% com um *codebook* de tamanho igual a 64.

Oleskovicz et al. (2006) apresentaram um estudo comparativo entre ferramentas de análise aplicadas à qualidade da energia elétrica (QEE), enfatizando a transformada de Fourier com janela (TFJ), a TW e redes neurais artificiais (RNA). Estas ferramentas foram utilizadas

para classificar os distúrbios agregados às formas de ondas de tensão referenciadas em um sistema real de distribuição. Na revisão dos conceitos básicos das ferramentas aplicadas no trabalho, os autores afirmam que para obter informações aceitáveis no estudo de fenômenos ligados à QEE, a obtenção de informações em ambos os domínios, tempo e frequência, são fundamentais na caracterização de fenômenos. De acordo com o trabalho, uma maneira de conseguir essas informações seria pela TFJ, sendo a janela ajustada e deslocada para explorar uma grande quantidade de dados referentes à QEE. No trabalho foi salientado que a TFJ, também conhecida como Transformada de Fourier de Curto Tempo, pode ser usada para análise no domínio do tempo e frequência de sinais não estacionários, visto que a TF tradicional torna-se inadequada. Em seguida, os autores comentam as definições e fazem comparações dos três tipos de janelas utilizadas no trabalho que são: janela Retangular, janela de Hanning e janela de Kaiser. Já na parte da TW foi feita uma pequena revisão da aplicação da TW no contexto da QEE e também foi explicada e exemplificada a técnica Análise Multiresolução, ressaltando sua principal característica que é a análise dos dados com escalas variáveis no domínio do tempo e frequência, permitindo a decomposição dos sinais em diferentes níveis de resolução.

Em relação às redes neurais, foi destacado o seu emprego em reconhecimento de padrões e por isso, segundo os autores, esta técnica apresenta características interessantes para a classificação de distúrbios relacionados à QEE. Baseados nestas informações, os autores afirmaram ser possível monitorar constantemente um sistema através dos valores amostrados de tensões, a uma frequência de 7,68 kHz. A idéia foi monitorar as três fases de tensões de um sistema de forma individual pela TW e pela TFJ, e tão logo fossem caracterizadas discontinuidades nos sinais, realizar o armazenamento de até 10 ciclos pós-fenômeno. Com as três abordagens, TW, TFJ e RNA, foram realizadas análises da QEE de um sistema real simulado pela aplicação do *software* ATP, sendo considerados cinco tipos de eventos: afundamento, elevação, interrupção, ruído e transitório oscilatório. Na observação dos resultados quando da aplicação da TFJ, para a função de detecção no tempo, o maior erro observado foi em torno de 0,4%, e para a classificação obtiveram um índice de 100% de acerto para todos os sinais analisados. Quando da análise do mesmo conjunto, através da TW, obtiveram um índice de 100% para a detecção e 95,5% para a classificação dos fenômenos. Além da classificação do fenômeno apresentado pela RNA, após a confirmação de determinada anomalia sobre o sistema, as abordagens baseadas na TFJ e na TW puderam então analisar os sinais e relatar os instantes de inserção e extinção.

**Considerações finais**

Neste capítulo da dissertação foi apresentada uma revisão dos principais artigos estudados que aplicam diversos métodos para a detecção e classificação de distúrbios através da TW. Estes trabalhos mostram a evolução da aplicação da TW em análise de distúrbios combinados com técnicas de inteligência artificial que ajudam ou executam o reconhecimento dos eventos. De acordo com a literatura a TW está sendo utilizada em processamento de sinais no lugar de técnicas como a transformada de Fourier. Uma das razões, é que para a aplicação da TW não é necessário assumir que o sinal é estacionário ou periódico, nem mesmo na janela de análise. Isto faz a TW altamente desejada para localizar mudanças em sinais incluindo, as mudanças rápidas com componentes de alta frequência.

## 5 ANÁLISE DE COMPONENTES PRINCIPAIS

Muitos dos algoritmos clássicos de processamento de sinais recorrem a métodos de descorrelação de dados. As vantagens de tais técnicas baseiam-se num princípio relativamente simples: ao descorrelacionar os dados, é eliminado parte da informação redundante em cada dimensão. Determinados sinais que apresentam uma substancial correlação entre amostras são os candidatos ideais para os algoritmos de descorrelação. Os benefícios resultantes são vários, tais como: os dados podem ser descritos de uma forma mais concisa, certas características escondidas nos dados podem se tornar transparentes depois de transformadas e a distribuição dos dados pode ser representada pelas densidades individuais de cada dimensão. Um dos métodos mais utilizados para a descorrelação de dados é o método denominado *análise de componentes principais* (ACP).

A idéia central da análise de componentes principais é reduzir a dimensão de um conjunto de dados que contenham um grande número de variáveis inter-relacionadas, enquanto retém a maior variação possível contida no conjunto de dados. Ela é uma das transformações mais representativas e compactas das observações. Isto é alcançado transformando os dados em um novo conjunto de variáveis. As componentes principais são descorrelacionadas e ordenadas para que as primeiras componentes contenham a maior parte da variação presente em todas as variáveis originais (JOLLIFFE, 2002).

O método de ACP transforma um vetor aleatório  $\mathbf{x} \in \mathbb{R}^m$  em outro vetor  $\mathbf{y} \in \mathbb{R}^p$  (para  $p \leq m$ ) projetando  $\mathbf{x}$  nas  $p$  direções ortogonais de maior variância – as componentes principais. Geralmente, grande parte da variância é explicada por um número reduzido de componentes, sendo possível o descarte das restantes sem perder informações relevantes. Por isso, o método de ACP é considerado uma técnica ótima para a redução linear de dimensões. Tal redução é vantajosa para compressão, visualização de dados, permitindo a redução do cálculo necessário em fases de processamento posteriores, que é o propósito da utilização da técnica neste trabalho.

A estimação das componentes principais é relativamente simples, basta utilizar a informação contida na matriz de covariância dos dados. Mas antes de descrever o método é necessário rever alguns conceitos utilizados em ACP.

## 5.1 Mudança de base

O objetivo do algoritmo ACP é verificar se: existe uma outra base, que é uma combinação linear da base original, que melhor represente o conjunto de dados analisado. Para isso, a ACP faz uma suposição de linearidade. Com esta suposição, a ACP é então limitada a expressar os dados como uma combinação linear dos seus vetores de base. Seja  $\mathbf{X}$  uma matriz  $m \times n$  que representa o conjunto de dados originais. Seja  $\mathbf{Y}$  uma outra matriz  $m \times n$  relacionada por uma transformação linear  $\mathbf{P}$ ,  $m \times m$ , ortonormal (CASTELLS et al., 2007).  $\mathbf{Y}$  é uma representação do conjunto de dados originais, conforme equação (5.1).

$$\mathbf{PX} = \mathbf{Y} \quad (5.1)$$

Seja também  $\mathbf{p}_i$  as linhas de  $\mathbf{P}$ ,  $\mathbf{x}_i$  as colunas de  $\mathbf{X}$  e  $\mathbf{y}_i$  as colunas de  $\mathbf{Y}$ . A equação (5.1) representa uma mudança de base e, portanto pode ter algumas interpretações como:

- a)  $\mathbf{P}$  é uma matriz que transforma  $\mathbf{X}$  em  $\mathbf{Y}$ .
- b) As linhas de  $\mathbf{P}$ ,  $\{\mathbf{p}_1, \dots, \mathbf{p}_m\}$ , representam um conjunto de novos vetores de base para expressar as colunas de  $\mathbf{X}$ .

A segunda interpretação pode ser melhor explicada escrevendo o produto  $\mathbf{PX}$ .

$$\mathbf{PX} = \begin{bmatrix} \mathbf{p}_1 \\ \vdots \\ \mathbf{p}_m \end{bmatrix} [\mathbf{x}_1 \quad \dots \quad \mathbf{x}_n] \quad (5.2)$$

$$\mathbf{Y} = \begin{bmatrix} \mathbf{p}_1 \cdot \mathbf{x}_1 & \dots & \mathbf{p}_1 \cdot \mathbf{x}_n \\ \vdots & \ddots & \vdots \\ \mathbf{p}_m \cdot \mathbf{x}_1 & \dots & \mathbf{p}_m \cdot \mathbf{x}_n \end{bmatrix} \quad (5.3)$$

Nota-se que cada coluna de  $\mathbf{Y}$  tem a seguinte forma:

$$\mathbf{y}_i = \begin{bmatrix} \mathbf{p}_1 \cdot \mathbf{x}_i \\ \vdots \\ \mathbf{p}_m \cdot \mathbf{x}_i \end{bmatrix} \quad (5.4)$$

Pode-se reconhecer que cada coeficiente de  $\mathbf{y}_i$  é um produto escalar de  $\mathbf{x}_i$  com a linha correspondente em  $\mathbf{P}$ . De fato, as linhas de  $\mathbf{P}$  formam um novo conjunto de vetores de base para representar as colunas de  $\mathbf{X}$ .

Assumindo linearidade, o problema se reduz a encontrar a mudança de base apropriada. Na transformação anterior, os vetores  $\{\mathbf{p}_1, \dots, \mathbf{p}_m\}$  se tornarão as componentes principais de  $\mathbf{X}$ , mas ainda restam algumas questões como:

- Qual a melhor forma de expressar  $\mathbf{X}$  ?
- Qual seria uma boa escolha para a base  $\mathbf{P}$  ?

A seguir será mostrado como se obtém as respostas para as questões acima no algoritmo de ACP.

## 5.2 Matriz de covariância

Em análise de dados, sejam quais forem estes dados, na maioria das vezes os conjuntos de dados analisados possuem mais de uma dimensão e o objetivo da análise estatística desses dados é geralmente verificar a existência de alguma relação entre as dimensões. O desvio padrão e a variância operam somente em uma dimensão. Porém, é útil ter medidas similares para descobrir quanto às dimensões variam em relação à média. Estas medidas representam a covariância, que é sempre medida entre duas dimensões, pois se é calculado a covariância entre uma dimensão e ela mesma, ou seja, se está calculando a variância (SHLENS, 2005).

Sejam dois conjuntos de medidas com média zero,  $A = \{a_1, a_2, \dots, a_n\}$ ,  $B = \{b_1, b_2, \dots, b_n\}$ , sendo  $\bar{A}$  e  $\bar{B}$  as médias dos conjuntos e o subscrito  $n$  o número de amostras. A covariância entre  $A$  e  $B$  pode ser definida como:

$$\sigma_{AB}^2 = \frac{\sum_{i=1}^n (A_i - \bar{A})(B_i - \bar{B})}{(n-1)} \quad (5.5)$$

A covariância mede o grau da relação linear entre duas variáveis. Um valor de covariância grande (pequeno) indica alta (baixa) redundância.

Equivalentemente, pode-se converter  $A$  e  $B$  nos vetores correspondentes  $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_n]$  e  $\mathbf{b} = [b_1 \ b_2 \ \dots \ b_n]$ , então é possível expressar a covariância como um produto escalar na forma da matriz

$$\sigma_{ab}^2 \equiv \frac{1}{n-1} \mathbf{a} \mathbf{b}^T, \quad (5.6)$$

onde  $\frac{1}{n-1}$  é uma constante para normalização.

Generalizando o caso anterior de dois para um número arbitrário de vetores fazendo os vetores  $\mathbf{x}_1 \equiv \mathbf{a}$ ,  $\mathbf{x}_2 \equiv \mathbf{b}$  e considerando vetores adicionais  $\mathbf{x}_3, \dots, \mathbf{x}_m$ , pode-se definir uma nova matriz  $\mathbf{X}$  com dimensão  $m \times n$ .

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1 \\ \vdots \\ \mathbf{x}_m \end{bmatrix} \quad (5.7)$$

Uma interpretação de  $\mathbf{X}$  é a seguinte. Cada linha de  $\mathbf{X}$  corresponde a todas as medidas de um particular  $\mathbf{x}_i$ . Cada coluna de  $\mathbf{X}$  corresponde a um conjunto de medidas de uma tentativa particular (ex.: instante de tempo). Assim, a definição para a matriz de covariância  $\mathbf{C}_X$  é apresentada na equação (5.8).

$$\mathbf{C}_X \equiv \frac{1}{n-1} \mathbf{X}\mathbf{X}^T, \quad (5.8)$$

onde:

- $\mathbf{C}_X$  é uma matriz quadrada  $m \times m$ .
- Os termos da diagonal de  $\mathbf{C}_X$  são as variâncias de cada medida particular.
- Os termos fora da diagonal de  $\mathbf{C}_X$  são as covariâncias entre os tipos de medidas.

Pode-se dizer que  $\mathbf{C}_X$  captura as correlações entre todos os possíveis pares de medidas e estas correlações refletem a redundância nas medidas. Os termos diagonais correspondem a uma dinâmica interessante se assumissem valores grandes e a uma dinâmica não interessante para valores ínfimos. Já, valores grandes para os termos fora da diagonal de  $\mathbf{C}_X$  corresponderiam a uma alta redundância e valores pequenos para os termos fora da diagonal de  $\mathbf{C}_X$  corresponderiam a uma baixa redundância.

Considerando o exposto anteriormente, onde  $\mathbf{X}$  é a matriz dos dados originais e  $\mathbf{Y}$  uma representação de  $\mathbf{X}$ , pode-se sumarizar os objetivos em: minimizar a redundância dos dados medidos pela covariância e maximizar a representação dos dados medidos pela variância. Por definição covariâncias devem ser não-negativas, portanto a covariância mínima é zero. Uma representação otimizada, da matriz de covariância de  $\mathbf{Y}$ , representada por  $\mathbf{C}_Y$ , é

fazer com que todos os termos fora da diagonal de  $\mathbf{C}_Y$  sejam nulos. Portanto,  $\mathbf{C}_Y$  deve ser uma matriz diagonal.

Existem muitos métodos para diagonalizar  $\mathbf{C}_Y$ , mas a ACP seleciona um método simples, assumindo  $\mathbf{P}$  uma matriz ortonormal.

### 5.3 Resolvendo a ACP: autovalores e autovetores

Uma matriz quadrada  $\mathbf{A}$  de  $m \times m$  é um operador linear  $T$  de  $\mathbb{R}^m \rightarrow \mathbb{R}^m$ . Um vetor  $\gamma \in \mathbb{R}^m$  não nulo é um autovetor de  $\mathbf{A}$  se existir um escalar  $\lambda$  tal que  $\mathbf{A}\gamma = \lambda\gamma$ . Sendo  $\gamma$  e  $\lambda$  um autovetor e um autovalor de  $\mathbf{A}$ , respectivamente, obtém-se:

$$\mathbf{A}\gamma = \lambda\gamma \quad (5.9)$$

$$(\mathbf{A} - \lambda\mathbf{I})\gamma = 0 \quad (5.10)$$

$$|\mathbf{A} - \lambda\mathbf{I}| = 0 \quad (5.11)$$

A equação (5.11) é denominada a *equação característica* do operador  $T$  ou da matriz  $\mathbf{A}$ . As raízes desta equação são os autovalores de  $\mathbf{A}$ . Para calcular um autovetor  $\gamma$  associado ao autovalor  $\lambda$ , basta resolver a equação (5.10).

Considerando novamente o conjunto de dados  $\mathbf{X}$ , uma matriz  $m \times n$ , onde  $m$  é o número do tipo de medidas e  $n$  é o número de amostras, o objetivo é: encontrar uma matriz ortogonal  $\mathbf{P}$  onde  $\mathbf{Y} = \mathbf{P}\mathbf{X}$  tal que  $\mathbf{C}_Y \equiv \frac{1}{n-1} \mathbf{Y}\mathbf{Y}^T$  é diagonal. As linhas de  $\mathbf{P}$  são as *componentes principais* de  $\mathbf{X}$ , ou seja, cada linha  $\mathbf{p}_i$  é um autovetor de  $\mathbf{X}\mathbf{X}^T$ ; a  $i^{\text{ésima}}$  diagonal de  $\mathbf{C}_Y$  é a variância de  $\mathbf{X}$  ao longo de  $\mathbf{p}_i$ .

Em suma, o cálculo da ACP de um conjunto de dados  $\mathbf{X}$  envolve: subtrair a média de cada dimensão, calcular a matriz de covariância, calcular os autovalores e autovetores da matriz de covariância.

### 5.4 Escolhendo as componentes

Quando se lida com dados muito correlacionados existe geralmente uma grande diferença entre o maior e o menor autovalor de  $\mathbf{X}\mathbf{X}^T$ . Isto indica que certas componentes variam pouco em relação às outras. Quando se deseja diminuir a dimensão dos dados através

da ACP tem-se que escolher as componentes que mais representam as características dos dados originais. Neste caso, podem-se descartar as dimensões de menor variância sem afetar substancialmente a qualidade dos dados.

A escolha das componentes principais é realizada da seguinte forma: a matriz que contém os autovetores é ordenada de forma que a primeira componente principal é o autovetor associado ao maior autovalor, a segunda componente é o autovetor associado ao segundo autovalor mais elevado e assim por diante. Isto representa as componentes em ordem de significância. No caso de se ter um conjunto de dados de dimensão  $m$ , onde se aplica a ACP calculando  $m$  autovalores e autovetores. Escolhendo os  $p$  primeiros autovetores, a dimensão final dos dados será  $p$  (para  $p \leq m$ ). Fazendo-se o seguinte:

$$\mathbf{Y}' = \mathbf{P}'_{m \times p}{}^T \mathbf{X}_{m \times n}, \quad (5.12)$$

onde  $\mathbf{X}_{m \times n}$  é a matriz de dados originais,  $\mathbf{P}'_{m \times p}$  é a matriz que contém as  $p$  primeiras componentes e  $\mathbf{Y}'$  é uma matriz  $p \times n$  que representa o novo conjunto de dados descorrelacionados.

### 5.5 Exemplo numérico

Seja um conjunto de dados de 2 dimensões e ao lado o conjunto de dados ajustados pela subtração da média de cada dimensão:

$$\text{Dados} = \begin{bmatrix} 2,5 & 2,4 \\ 0,5 & 0,7 \\ 2,2 & 2,9 \\ 1,9 & 2,2 \\ 3,1 & 3,0 \\ 2,3 & 2,7 \\ 2,0 & 1,6 \\ 1,0 & 1,1 \\ 1,5 & 1,6 \\ 1,1 & 0,9 \end{bmatrix}, \quad \text{Dados Ajustados} = \begin{bmatrix} 0,69 & 0,49 \\ -1,31 & -1,21 \\ 0,39 & 0,99 \\ 0,09 & 0,29 \\ 1,29 & 1,09 \\ 0,49 & 0,79 \\ 0,19 & -0,31 \\ -0,81 & -0,81 \\ -0,31 & -0,31 \\ -0,71 & -1,01 \end{bmatrix}$$

A matriz de covariância é calculada de através da equação (5.8). Como os dados têm dimensão igual a 2 a matriz de covariância será  $2 \times 2$ :

$$\text{cov} = \begin{bmatrix} 0,6165555555555556 & 0,6154444444444445 \\ 0,6154444444444445 & 0,7165555555555555 \end{bmatrix},$$

tendo esta os seguintes autovalores e autovetores:

$$\text{autovalores} = \begin{bmatrix} 0,0490833989 & 0 \\ 0 & 1,284027713 \end{bmatrix},$$

$$\text{autovetores} = \begin{bmatrix} -0,735178656 & 0,677873399 \\ 0,677873399 & 0,735178656 \end{bmatrix}.$$

Observando os autovalores e os autovetores anteriores, percebe-se que os autovalores são valores diferentes. De fato, isto indica que o autovetor associado ao maior autovalor é a *componente principal* do conjunto de dados. O próximo passo então é ordenar os autovetores em ordem de significância representada pelos autovalores, do maior para o menor, neste caso basta trocar as colunas dos *autovetores*.

$$\text{componentes principais} = \begin{bmatrix} 0,677873399 & -0,735178656 \\ 0,735178656 & 0,677873399 \end{bmatrix}.$$

Existe a possibilidade, no caso de compressão de dados, de se descartar a componente menos significativa (segunda coluna), restando apenas uma coluna:

$$\text{componente principal} = \begin{bmatrix} 0,677873399 \\ 0,735178656 \end{bmatrix}$$

Os dados finais podem ser determinados da seguinte maneira:

$$\text{Dados Finais} = \text{Dados Ajustados} \times \text{componentes principais}$$

$$\text{Dados Finais} = \begin{bmatrix} 0,69 & 0,49 \\ -1,31 & -1,21 \\ 0,39 & 0,99 \\ 0,09 & 0,29 \\ 1,29 & 1,09 \\ 0,49 & 0,79 \\ 0,19 & -0,31 \\ -0,81 & -0,81 \\ -0,31 & -0,31 \\ -0,71 & -1,01 \end{bmatrix} \times \begin{bmatrix} 0,677873399 & -0,735178656 \\ 0,735178656 & 0,677873399 \end{bmatrix}$$

$$Dados\ Finais = \begin{bmatrix} 0,827970186 & -0,175115307 \\ -1,77758033 & 0,142857227 \\ 0,992197494 & 0,384374989 \\ 0,274210416 & 0,130417207 \\ 1,675801418 & -0,209498461 \\ 0,91294910 & 0,175282444 \\ -0,09910943 & -0,349824698 \\ -1,14457216 & 0,0464172582 \\ -0,438046137 & 0,0177646297 \\ -1,22382056 & -0,162675287 \end{bmatrix},$$

sendo estes novos dados completamente descorrelacionados. Para provar isto basta calcular a covariância *dos Dados Finais*.

$$cov(Dados\ Finais) = \begin{bmatrix} 1,284027713 & 0 \\ 0 & 0,0490833989 \end{bmatrix},$$

sendo esta uma matriz diagonal, fica provado que os dados são descorrelacionados, e nota-se também que esta matriz de covariância são os próprios *autovalores* obtidos anteriormente.

## 5.6 Considerações finais

A análise de componentes principais é uma forma de identificar padrões nos dados e expressar esses dados de tal modo que destaque as suas similaridades e diferenças. Uma outra vantagem da ACP é que uma vez encontrados os padrões nos dados, pode-se comprimir os dados, ou seja, reduzir o número de dimensões, sem muita perda de informação. Por isso, este método possui uma vasta gama de aplicações inclusive em estudos de qualidade da energia elétrica.

## 6 METODOLOGIA APLICADA PARA CLASSIFICAÇÃO DOS DISTÚRBIOS

Nesta etapa do trabalho é apresentada a metodologia proposta para a análise e classificação de diferentes distúrbios relacionados à qualidade da energia elétrica. Esta metodologia é composta de 4 etapas principais:

- (1) Análise dos sinais utilizando a transformada *wavelet*;
- (2) Extração das características dos sinais;
- (3) Redução do tamanho dos vetores de dados que representam cada sinal analisado;
- (4) Classificação dos diferentes distúrbios.

A Figura 6.1 mostra o diagrama de classificação proposto. Esta metodologia de classificação tem como principais objetivos não só fazer o uso da ferramenta *wavelet* para discriminar sinais de distúrbios, mas também reduzir o número de dados e conseqüentemente o tempo de processamento gasto para realizar as classificações.

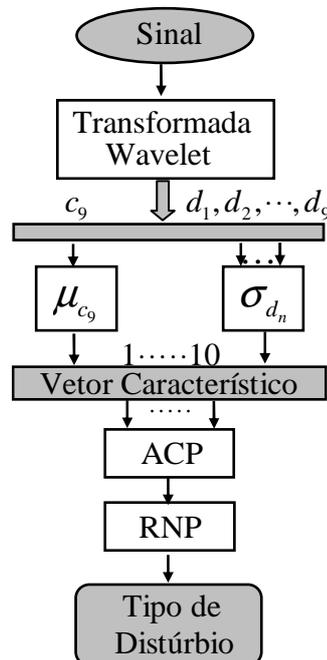


Figura 6.1 – Diagrama do algoritmo de classificação de distúrbios.

### 6.1 Análise dos sinais

Nesta etapa inicial do algoritmo de classificação os sinais a serem analisados são decompostos em 9 níveis de resolução através da análise multiresolução, descrita no capítulo

4 desta dissertação. A *wavelet* mãe escolhida para analisar os sinais foi a “db4” da família de *wavelets Daubechies*, por possuir suporte compacto e por ser uma das *wavelets* mais utilizadas para aplicações em qualidade da energia (CHEN; ZHU, 2007; GAING, 2004; OLESKOVICZ et al., 2006; SANTOSO et al., 2000).

Os sinais são decompostos e ficam representados pelos coeficientes das aproximações e dos detalhes. Considerando como exemplo um sinal  $c_0(n)$  em tempo discreto que é decomposto em aproximação e detalhes através da AMR. As representações deste sinal na escala 1 são  $c_1(n)$  e  $d_1(n)$ , obtidos pelas equações 6.1 e 6.2, que representam os coeficientes de aproximação e de detalhes do sinal original  $c_0(n)$ , respectivamente.

$$c_1(n) = \sum_k h(k - 2n)c_0(k) \quad (6.1)$$

$$d_1(n) = \sum_k g(k - 2n)c_0(k) \quad (6.2)$$

Os parâmetros  $h(n)$  e  $g(n)$  são os coeficientes dos filtros (FIR - *finit impulse response*) passa-baixa e passa-alta, respectivamente, utilizados pela *wavelet* “db4”, que decompõem o sinal  $c_0(n)$  em  $c_1(n)$  e  $d_1(n)$ . A implementação da AMR para dois níveis está ilustrada na Figura 6.2. No caso desta proposta, a decomposição ocorre até 9 níveis, de onde se obtém o coeficiente de aproximação  $c_9$  e os coeficientes de detalhes ( $d_1 - d_9$ ).

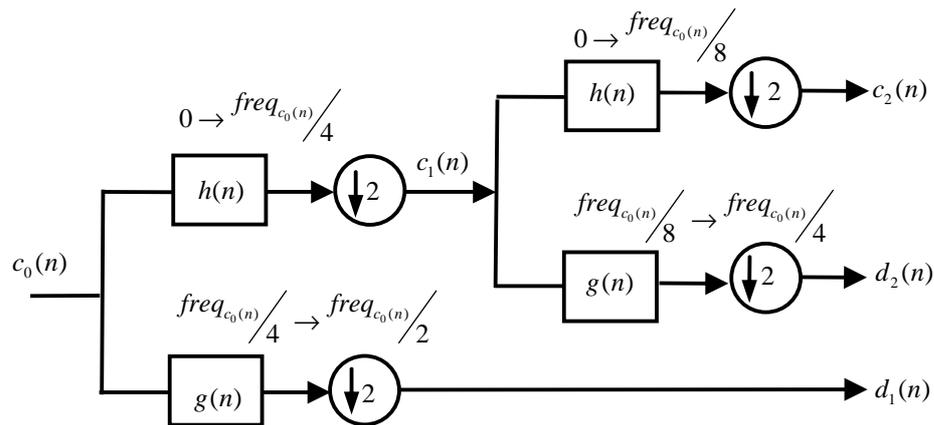


Figura 6.2 – Ilustração da decomposição de  $c_0(n)$  em duas escalas.

Ainda na Figura 6.2, como pode ser observado, estão representadas as faixas de frequências que cada nível de resolução irá conter, dependendo da taxa em que o sinal de entrada é amostrado. Para esta aplicação, a taxa de amostragem dos sinais é de 15,36 kHz, *Giovani Guarienti Pozzebon* CEEMA/2009

portanto, a frequência máxima do sinal de entrada que pode ser analisada é de 7,68 kHz. As faixas de frequências em cada nível e as respectivas harmônicas estão apresentadas na Tabela 6.1, obtidas através da equação 4.15.

Tabela 6.1 – Relação entre as escalas e faixas de frequências

Nível	Parâmetro	Faixa de Frequência (Hz)	Harmônicos
9	$c_{9,k}$	0 – 15	-
9	$d_{9,k}$	15 – 30	-
8	$d_{8,k}$	30 – 60	1°
7	$d_{7,k}$	60 – 120	1° – 2°
6	$d_{6,k}$	120 – 240	2° – 4°
5	$d_{5,k}$	240 – 480	4° – 8°
4	$d_{4,k}$	480 – 960	8° – 16°
3	$d_{3,k}$	960 – 1920	16° – 32°
2	$d_{2,k}$	1920 – 3840	32° – 64°
1	$d_{1,k}$	3840 – 7680	64° – 128°

Considerou-se para esta aplicação, sinais de tensão em regime permanente, contendo distúrbios como afundamentos, interrupções, harmônicos, transitórios oscilatórios, *notches* e *flickers*. A seguir são apresentados três casos de decomposição de sinais pela AMR. Como primeira situação, tem-se, na Figura 6.3, um sinal de tensão caracterizando um afundamento de tensão sem a presença de harmônicos. Na Figura 6.4, tem-se um sinal de tensão também caracterizando um afundamento de tensão com a presença de harmônicos. Estes sinais foram decompostos em 9 níveis de resolução com a *wavelet* db4.

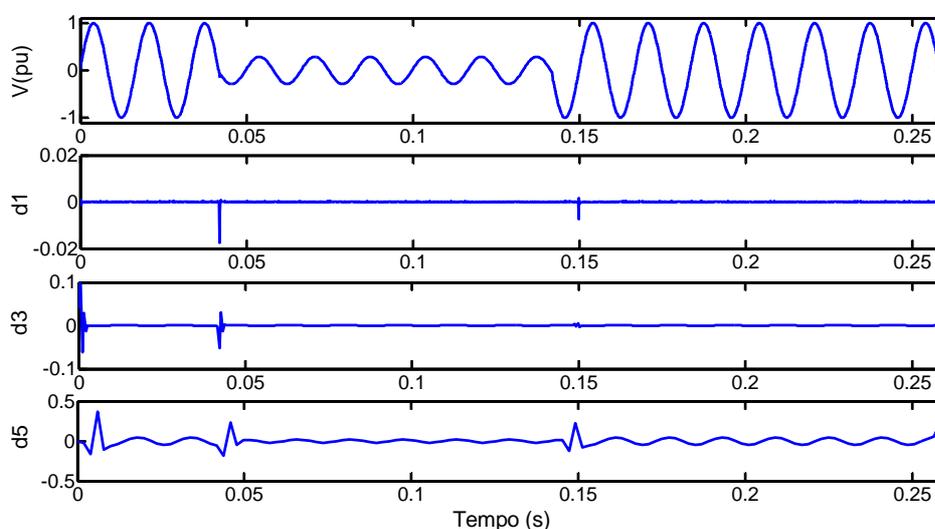


Figura 6.3 – Decomposição de um sinal de tensão com afundamento e sem a presença de harmônicos.

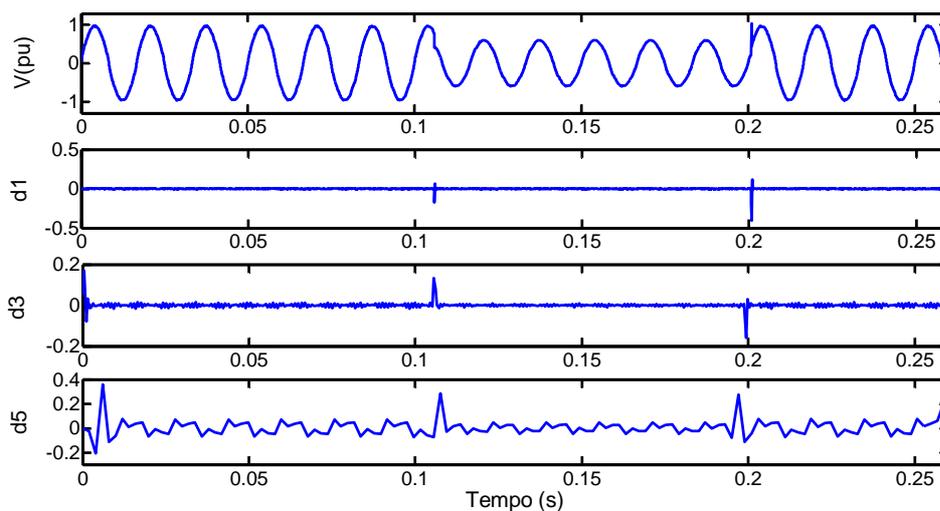


Figura 6.4 – Decomposição de um sinal de tensão com afundamento e harmônicos.

É possível perceber claramente através dos coeficientes de detalhes, os instantes onde começam e terminam os afundamentos, bem como a presença ou não de conteúdos harmônicos, principalmente nos coeficientes d3 e d5.

Na Figura 6.5 são apresentadas as decomposições em 3 níveis de resoluções de um sinal de tensão com distúrbio de transitório oscilatório proveniente de chaveamento de capacitores. Neste caso, percebe-se a caracterização do distúrbio nos primeiros níveis de resolução, por se tratar de um fenômeno com frequências altas.

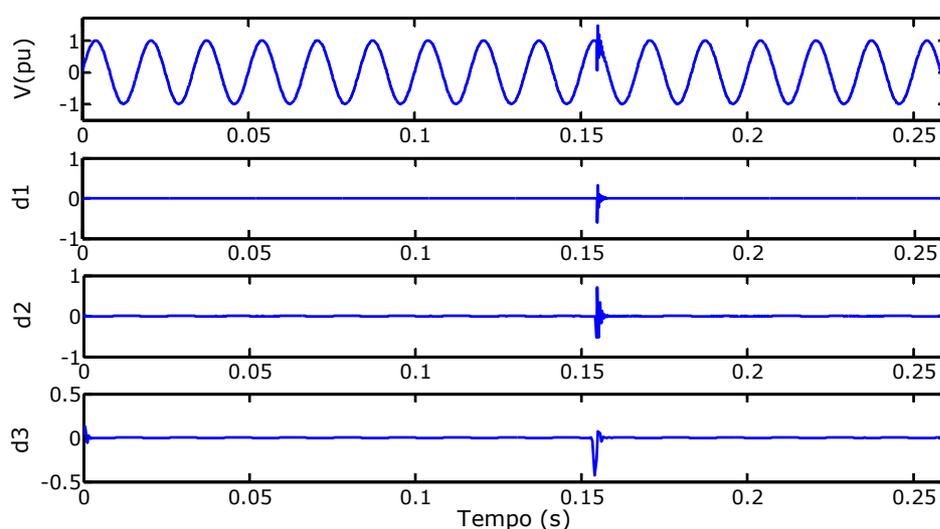


Figura 6.5 – Sinal de tensão com transitório oscilatório.

A decomposição dos sinais pela AMR permite separar em detalhes os conteúdos originados pelos distúrbios, em diferentes bandas de frequência. Assim, é possível determinar através dos coeficientes de detalhes quais tipos de fenômenos estão sendo caracterizados.

## 6.2 Extração de características

A análise de sinais com a utilização da TW e AMR apresenta as variações nos coeficientes de detalhes provenientes das decomposições. Portanto, há a necessidade de se quantificar tais variações contidas em cada nível de resolução. Para isto, assim como nos trabalhos de Kanitpanyacharoen et al. (2004) e Delmont (2003 e 2007), utilizou-se o método da curva de desvio padrão das decomposições em AMR, pois o desvio padrão é considerado como uma medida de energia para um sinal com média zero. O desvio padrão é a raiz quadrada da variância, conforme mostra a equação 6.3.

$$dp = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (6.3)$$

onde  $dp$  é o desvio padrão em cada nível de decomposição,  $x_i$  são os pontos do vetor de detalhes em cada nível de decomposição e  $\bar{x}$  é a média dos pontos em cada nível de decomposição.

A Figura 6.6 mostra a curva de desvio padrão obtida da análise de um sinal contendo um afundamento de tensão comparado com a curva de desvio padrão das decomposições de uma senóide pura.

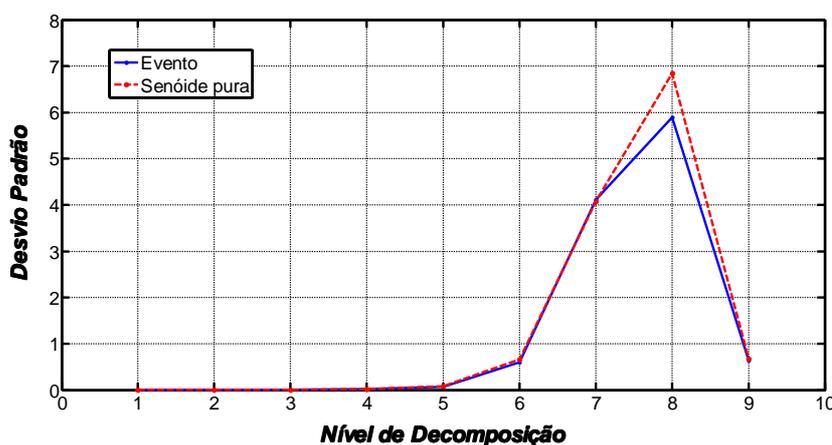


Figura 6.6 – Curvas de desvios padrões obtidas da análise de um sinal de tensão com afundamento e de uma senóide pura.

Observando a Figura 6.6, percebe-se claramente que houveram variações acentuadas nos coeficientes de detalhes do oitavo nível de resolução, que é onde se concentra a maior parte das componentes de frequência fundamental do sinal. Neste caso, ocorreu uma

diminuição da amplitude dessas componentes, o que é de se esperar quando ocorre um afundamento na forma de onda da tensão.

Já na Figura 6.7, está ilustrada a curva de desvio padrão dos coeficientes de detalhes provenientes da AMR de um sinal de tensão contendo um oscilatório transitório causado por chaveamento de capacitores.

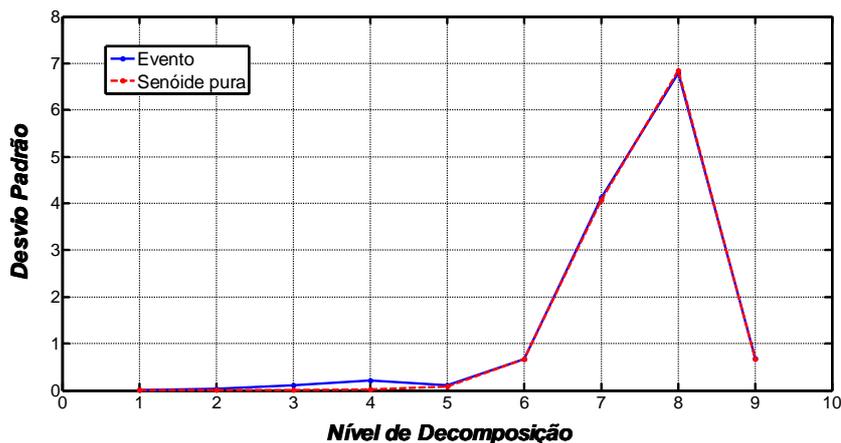


Figura 6.7 – Curvas de desvios padrões obtidas da análise de um sinal de tensão com transitório oscilatório e de uma senóide pura.

Diferentemente da Figura 6.6, que apresenta variações no nível 8, a Figura 6.7 mostra pequenas variações nos desvios padrões que representam os níveis 3 e 4 em relação à senóide pura. Estas variações se devem ao fato de que as inserções de capacitores nos sistemas de energia causam transitórios oscilatórios com faixas de frequência bem maiores que a frequência fundamental do sistema. Observando-se a Tabela 6.1, é possível conferir as faixas de frequência representadas pelos coeficientes de detalhes 3 e 4.

Através de testes e simulações realizados para o método proposto e ainda considerando o número total de amostras para representar a janela dos sinais, chegou-se a resultados satisfatórios utilizando-se 9 níveis de decomposição. Utilizando-se somente os coeficientes de detalhes, conforme a Tabela 6.1, é possível representar quase toda a faixa de frequência dos sinais, restando somente uma pequena faixa de 0 a 15 Hz que fica representada pelos coeficientes de aproximações.

De forma a considerar as características originadas pelos distúrbios em baixa frequência, ou seja, menores que 15 Hz, que é o caso do fenômeno *flicker*, utilizou-se o cálculo da média dos coeficientes de aproximação dos sinais. A média é definida por:

$$\mu_x = \frac{1}{n} \sum_{i=1}^n x_i, \quad (6.4)$$

onde  $\mu_x$  é a média do vetor que contém os coeficientes de aproximação  $c_{9,k}$ ,  $x_i$  são os pontos do vetor de coeficientes de aproximação do último nível de decomposição.

As características obtidas através dos desvios padrões e da média compõem um vetor característico  $\mathbf{x}_i$  para cada sinal com distúrbio analisado. Seja  $\sigma_d$  os desvios padrões de cada nível de decomposição e  $\mu_{c_L}$  a média dos coeficientes de aproximação no último nível, o vetor característico pode ser representado por:

$$\mathbf{x}_i = \begin{bmatrix} \sigma_{d_1} \\ \sigma_{d_2} \\ \vdots \\ \sigma_{d_L} \\ \mu_{c_L} \end{bmatrix}, \quad (6.5)$$

onde,  $L$  é o número de níveis de decomposição, que neste caso é 9;  $i = 1, 2, \dots, N$ , sendo  $N$  o número total de sinais analisados e  $M = L + 1 = 10$  é o tamanho de cada vetor  $\mathbf{x}_i$ .

### 6.3 Redução de dados através da ACP

A idéia essencial da ACP é reduzir a dimensionalidade de um conjunto de dados que contenha um grande número de variáveis correlacionadas, retendo a maior variação possível presente no conjunto de dados. No caso desta proposta, a ACP é utilizada para reduzir o tamanho do vetor que representa cada um dos sinais analisados, representados pela equação 6.5, além de eliminar dados redundantes.

O conjunto de vetores  $\mathbf{x}_i$ , iguais ao da equação 6.5, que representam  $N$  sinais observados e analisados pela AMR, formam uma matriz  $M \times N$  da forma:

$$\mathbf{X}_{M \times N} = [\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_N], \quad (6.6)$$

que será utilizada para o cálculo das componentes principais, utilizando o método descrito no capítulo 5 desta dissertação.

Após o cálculo das componentes principais é necessário escolher o número de componentes principais a serem utilizadas para representar cada vetor. Deste modo, o critério utilizado neste trabalho foi considerar as  $P$  primeiras componentes que representassem mais de 90% da variabilidade dos dados, ou seja,  $\beta_p > 90\%$ , sendo:

$$\beta_p = \frac{\sum_{k=1}^p \lambda_k}{\sum_{k=1}^M \lambda_k} \times 100\% , \quad (6.7)$$

onde  $\lambda_k$  são os autovalores calculados da matriz de covariância de  $\mathbf{X}$ ,  $M = 10$  (tamanho de cada vetor) e  $P$  é o número de componentes principais. Para este trabalho foram utilizadas as 3 primeiras componentes principais, ou seja,  $P = 3$ .

A Figura 6.8 ilustra a variância, que são os autovalores  $\lambda_k$ , de 4 componentes principais resultantes da técnica ACP aplicada em um conjunto de vetores, obtidos da extração de características e AMR, que representam sinais com distúrbios. Nesta figura, são apresentadas as contribuições individuais de cada componente, bem como a variância cumulativa (equação 6.7), que para as 3 primeiras componentes, apresentadas no exemplo, resultou em 92,97%.

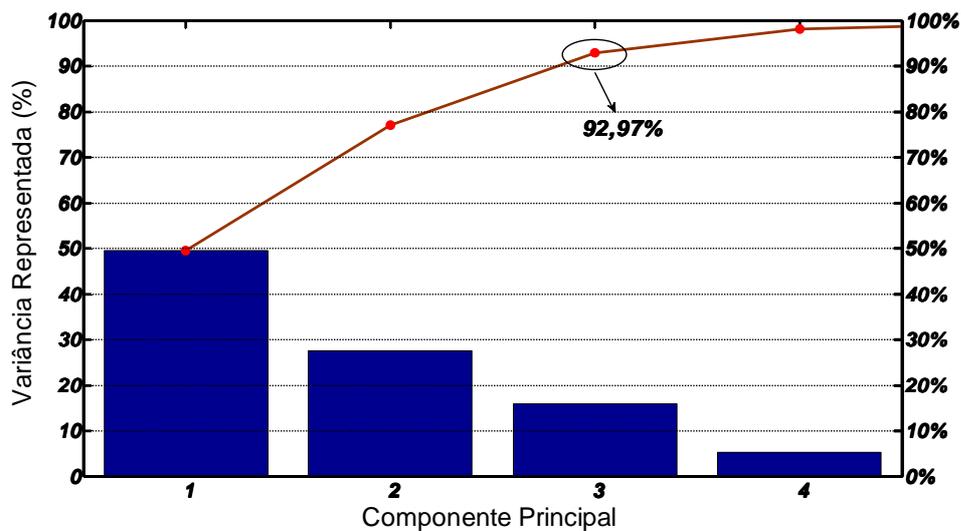


Figura 6.8 – Variância representada pelas 4 primeiras componentes principais.

Com a definição das componentes principais é possível obter, através da equação 5.12, um novo conjunto  $\mathbf{X}'$  de dados linearmente independentes, de dimensão  $P \times N$  (para  $P \leq M$ ) menor que os dados de entrada, o qual representa significativamente os dados originais. Para o caso de se realizar uma classificação utilizando redes neurais, isto permite uma redução dos dados de entradas na rede neural, ou seja, reduz a quantidade de dados a serem processados e, conseqüentemente, há uma redução no período para a execução da classificação pela rede.

#### 6.4 Método de classificação de distúrbios utilizando uma rede neural probabilística

A classificação dos distúrbios relacionados à QEE é a última etapa do algoritmo proposto, sendo que para executar tal classificação, é utilizada uma rede neural probabilística. As Redes Neurais Probabilísticas (RNPs) foram inspiradas nos Classificadores Bayesianos e são um excelente método de classificação (TOU et al., 1974), elas foram idealizadas por Donald Specht (SPECHT, 1990) ganhando este nome devido suas raízes se basearem nas Teorias da Probabilidade.

A vantagem mais importante das RNPs em relação a outras redes é seu processo de treinamento rápido, o que as tornam desejáveis para a classificação em tempo real (YANG et al., 2006). Em aplicações de classificação de sinais, os dados são classificados de acordo com suas funções de densidade de probabilidade (PDF). Uma simples definição para esta função pode ser encontrada em Tou et al. (1974), Specht (1990) e Laurene (1994).

A Figura 6.8 mostra a arquitetura de uma RNP. Essa rede possui apenas três camadas: camada de entrada, camada escondida e camada de saída (camada competitiva). Outra vantagem desse tipo de rede é prescindir da determinação do número de neurônios na camada escondida. O número de neurônios na camada escondida é definido de acordo com o número de vetores utilizados para o treinamento. Na camada de saída, a quantidade de neurônios é a mesma das classes a serem reconhecidas.

Nesta aplicação, as entradas da rede neural são os conjuntos de dados (vetores) obtidos através da ACP,  $\mathbf{X}'_{P \times N} = [\mathbf{x}'_1 \quad \mathbf{x}'_2 \quad \dots \quad \mathbf{x}'_N]$ . A camada escondida da rede neural calcula as distâncias entre o vetor de entrada  $\mathbf{x}'_i$  e os vetores de pesos contidos na matriz de pesos  $W^1$ . Estas distâncias são escaladas pela função de transferência RBF (*Radial Basis Function*). A camada competitiva encontra a menor distância entre elas e então o padrão de treinamento, semelhante ao padrão de entrada baseado nas distâncias, pode ser encontrado (YANG et al., 2006).

Na Figura 6.9, a matriz de pesos  $W^1$ , cuja dimensão é  $Q \times P$ , conecta a camada de entrada com a camada escondida que contém a função de transferência. O parâmetro  $Q$  é o número de combinações da entrada para a saída e  $P$  é a dimensão do vetor de entrada  $\mathbf{x}'_i$ . Ainda na Figura 6.9,  $b^1$  é o vetor de polaridade e o bloco onde contém  $\|dist\|$  produz um vetor cujos elementos indicam quão perto a entrada está em relação aos vetores do conjunto de treinamento. Estes elementos são multiplicados, elemento por elemento, pelo vetor de

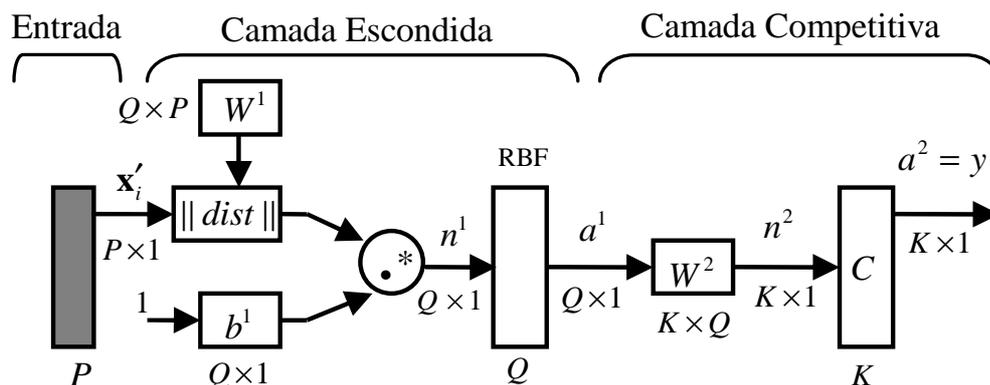


Figura 6.9 – Estrutura de uma Rede Neural Probabilística.

polaridade resultando  $n^1$ . O parâmetro  $a^1$  é o vetor de saída da função de transferência (RBF) da camada escondida. A matriz de pesos  $W^2$  conecta a camada escondida com a camada competitiva. Na camada competitiva, o vetor  $a^1$  é multiplicado pela matriz de pesos  $W^2$ , produzindo um vetor de saída  $n^2$ . A função de transferência competitiva, denotada por  $C$  na Figura 6.9, produz uma saída 1 correspondendo ao maior elemento de  $a^1$  e 0 (zero) para os outros elementos. O vetor de saída da função competitiva  $C$  é denotado como  $a^2 = y$ . A indexação do 1 em  $a^2$  é o número de classes que o sistema pode classificar. A dimensão do vetor de saída,  $K$ , é o número de classes de distúrbios que se deseja classificar.

## 6.5 Considerações finais

Nesta parte do trabalho foi apresentada a metodologia proposta para a análise e classificação de diferentes distúrbios relacionados à qualidade da energia elétrica. Viu-se que através da utilização desta metodologia que os sinais são analisados pela TW a fim de se extrair características no domínio do tempo e frequência obtendo uma boa discriminação entre os distúrbios. Estas características são medidas pelas curvas de desvio padrão e média das componentes obtidas da AMR.

Com o intuito de reduzir a quantidade de dados e o tempo requerido para a classificação dos distúrbios, propôs-se aplicar a análise de componentes principais para decorrelacionar variáveis contidas nos vetores de características e por fim, escolher as mais significativas para se utilizar na classificação.

Para a etapa de classificação, optou-se por um método de reconhecimento de padrões através de redes neurais artificiais, mais especificamente, uma rede neural probabilística, tendo como saída o tipo de distúrbio contido nos sinais analisados.

## 7 RESULTADOS DAS CLASSIFICAÇÕES DOS DISTÚRBIOS

A metodologia de classificação dos distúrbios relacionados à qualidade da energia elétrica é aplicada em dois casos. No primeiro caso, são consideradas 7 classes de distúrbios sendo que, os sinais pertencentes a estas classes são analisados e classificados de duas formas: a primeira sem utilizar a análise de componentes principais e a outra utilizando a análise de componentes principais. Este procedimento foi adotado para que se possa avaliar o tempo de classificação e evidenciar as vantagens da utilização da ACP na redução de dados de QEE.

Já no segundo caso, a proposta de aplicação do algoritmo está relacionada aos efeitos causados pela inserção de sistemas de geração distribuída (GD) em redes de distribuição. Neste segundo caso, os sinais obtidos de eventos decorrentes da análise de sistemas de GD conectados em redes de distribuição são analisados pela TW. Em seguida estes são associados aos sinais do primeiro caso para serem classificados em quatro novas classes.

### 7.1 Classificação de distúrbios típicos

Este é o primeiro caso, no qual foram analisados e classificados distúrbios como afundamento e interrupção de tensão, transitório oscilatório proveniente de chaveamento de capacitor, *flicker*, distorção harmônica, *notching* bem como sinal senoidal puro, totalizando 7 classes consideradas da seguinte forma (POZZEBON et al., 2008):

$D_1 \rightarrow$  Senóide pura.

$D_2 \rightarrow$  Transitório oscilatório.

$D_3 \rightarrow$  *Flicker*.

$D_4 \rightarrow$  Harmônicos.

$D_5 \rightarrow$  Interrupção de tensão.

$D_6 \rightarrow$  *Notching*.

$D_7 \rightarrow$  Afundamento de tensão.

A base de dados utilizada para treinamento da rede neural e classificação foi gerada por diversas simulações utilizando os softwares PSIM<sup>®</sup> e MATLAB/Simulink<sup>®</sup>. Com uma frequência de amostragem de 15,36 kHz e uma amplitude de 1,0 p.u. para todos os sinais. O algoritmo de classificação foi executado em MATLAB<sup>®</sup>.

Para a validação da proposta de classificação, foram adotados os seguintes procedimentos (POZZEBON et al., 2008): primeiramente, os sinais pertencentes à base de dados foram separados em 4 grupos A, B, C e D. Cada um desses grupos contendo 231 sinais, igualmente distribuídos, ou seja, 33 sinais de cada classe de distúrbio, totalizando 924 sinais. Em seguida, foi empregado um grupo de cada vez para treinamento da rede neural, enquanto os grupos restantes foram utilizados para classificação. Por exemplo, quando o grupo A é utilizado para treinar o sistema de classificação, os grupos B, C e D são utilizados para teste. Dessa forma obteve-se 8 conjuntos de resultados de classificação sendo que 4 grupos não utilizavam a ACP e 4 utilizavam a ACP.

### 7.1.1 Resultados das classificações sem a ACP

Para a classificação dos distúrbios sem a ACP os vetores característicos de cada distúrbio, representados pela equação 6.5, foram inseridos diretamente na rede neural para treinamento e posteriormente para classificação.

As tabelas apresentadas a seguir contêm em suas linhas os sinais com distúrbios a serem classificados e nas colunas as classes onde estes sinais foram classificados. Também são apresentadas as resoluções de classificações obtidas para cada conjunto de treinamento, onde as mesmas são: 92,06%, 94,08%, 93,07% e 94,23%, para os grupos A, B, C e D, respectivamente.

A Tabela 7.1 apresenta os resultados obtidos das classificações das sete classes de sinais, considerando o grupo A como grupo de treinamento da rede neural.

Tabela 7.1 – Resultados das classificações sem a ACP e utilizando o grupo A para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	3	<b>94</b>	0	0	0	2	0
<i>Flicker</i>	12	3	<b>81</b>	0	0	2	1
Harmônicos	1	0	0	<b>97</b>	0	0	1
Interrupção de tensão	0	0	0	0	<b>90</b>	0	9
<i>Notching</i>	3	3	0	0	0	<b>93</b>	0
Afundamento de tensão	0	1	1	0	8	5	<b>84</b>
Resolução da classificação: <b>92,06%</b>							

Na Tabela 7.2, são apresentados os resultados das classificações quando da utilização do grupo B para treinamento da rede neural. Na seqüência, as Tabelas 7.3 e 7.4 apresentam os

Tabela 7.2 – Resultados das classificações sem a ACP e utilizando o grupo B para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	0	<b>99</b>	0	0	0	0	0
<i>Flicker</i>	8	4	<b>86</b>	0	0	1	0
Harmônicos	1	0	0	<b>97</b>	0	0	1
Interrupção de tensão	0	0	0	0	<b>92</b>	0	7
<i>Notching</i>	1	4	0	0	0	<b>94</b>	0
Afundamento de tensão	0	0	0	0	5	9	<b>85</b>
Resolução da classificação: <b>94,08%</b>							

Tabela 7.3 – Resultados das classificações sem a ACP e utilizando o grupo C para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	0	<b>98</b>	0	0	0	1	0
<i>Flicker</i>	13	6	<b>78</b>	0	0	2	0
Harmônicos	1	0	0	<b>97</b>	0	0	1
Interrupção de tensão	0	0	0	0	<b>95</b>	0	4
<i>Notching</i>	6	3	0	0	0	<b>90</b>	0
Afundamento de tensão	2	0	0	0	8	1	<b>88</b>
Resolução da classificação: <b>93,07%</b>							

Tabela 7.4 – Resultados das classificações sem a ACP e utilizando o grupo D para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	0	<b>92</b>	0	0	0	7	0
<i>Flicker</i>	11	1	<b>85</b>	0	0	1	1
Harmônicos	0	0	0	<b>99</b>	0	0	0
Interrupção de tensão	0	0	0	0	<b>97</b>	0	2
<i>Notching</i>	6	0	0	0	0	<b>93</b>	0
Afundamento de tensão	2	0	0	0	8	1	<b>88</b>
Resolução da classificação: <b>94,23%</b>							

resultados das classificações utilizando os grupos C e D para treinamento da rede neural, respectivamente.

### 7.1.2 Resultados das classificações com a ACP

A classificação dos distúrbios com a utilização da ACP foi realizada com os mesmos grupos anteriores. A única diferença deste procedimento para o anterior é que os vetores que caracterizam os distúrbios foram reduzidos e descorrelacionados antes de serem inseridos na rede neural.

A análise de componentes principais foi feita para cada um dos grupos que foram utilizados como grupos de treinamento. A Figura 7.1 mostra as 10 componentes principais obtidas dos conjuntos de vetores característicos de cada um dos quatro grupos. Já na Figura 7.2, são mostradas as quatro primeiras componentes principais separadamente, bem como as variâncias representadas por elas e as variâncias acumuladas pelas três primeiras componentes que foram utilizadas.

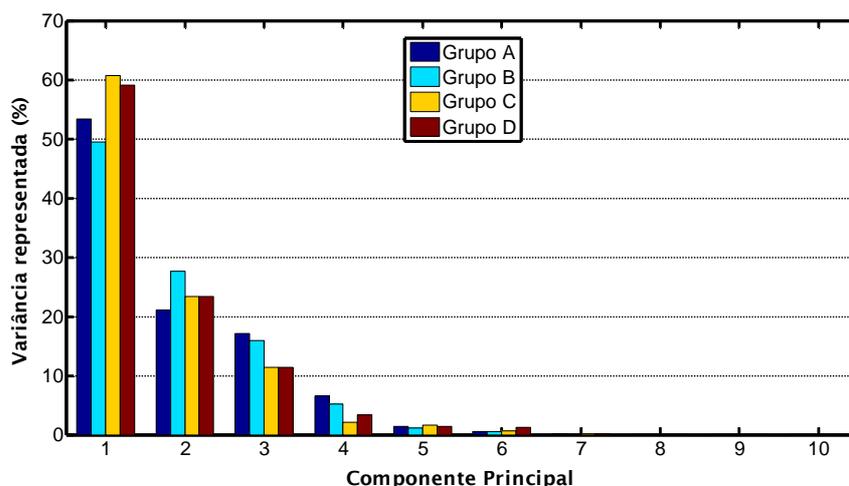


Figura 7.1 – Variância representada pelas componentes principais dos diferentes grupos.

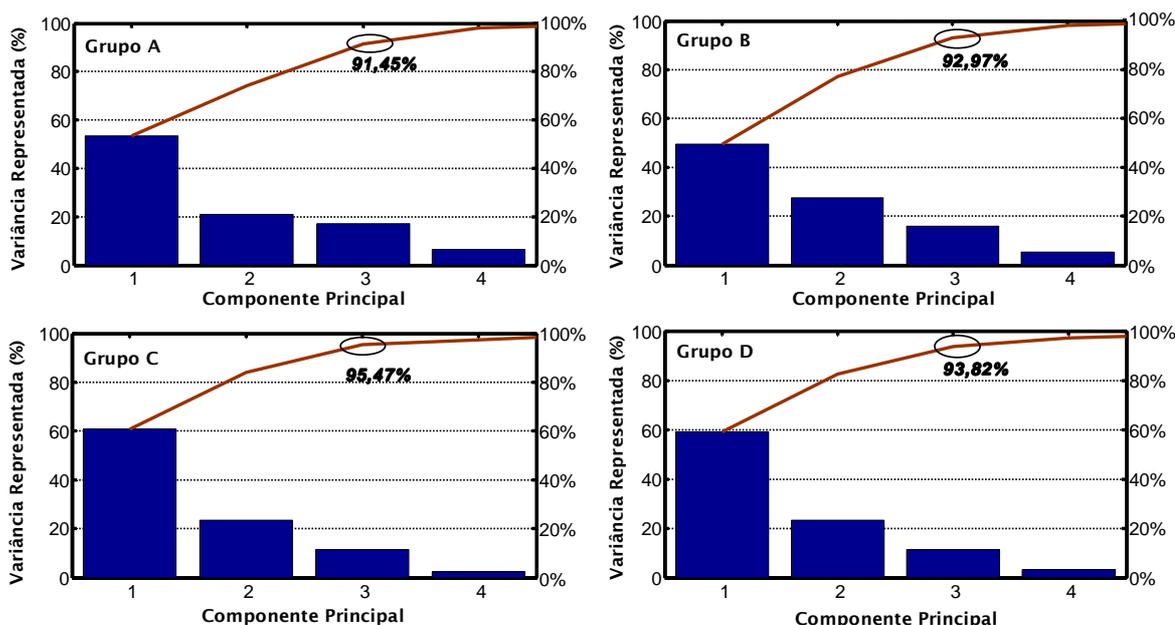


Figura 7.2 – Variâncias representadas pelas 4 primeiras componentes principais e variâncias acumuladas pelas 3 primeiras componentes em cada um dos grupos.

No procedimento de classificação, foram calculados novos conjuntos de dados decorrelacionados, para cada um dos grupos a serem classificados, a partir das componentes principais obtidas dos grupos de treinamento correspondentes. Estes novos conjuntos de dados foram obtidos através da equação 5.12, onde  $\mathbf{P}'_{m \times p}$ , representa a matriz  $10 \times 3$  com as 3 primeiras componentes obtidas a partir dos vetores característicos do grupo de treinamento considerado, sendo  $m = 10$  e  $p = 3$ , e  $\mathbf{X}_{m \times n}$  é a matriz que contém os vetores característicos dos grupos de sinais a serem classificados, sendo  $m = 10$  e  $n$  o número de sinais;  $\mathbf{Y}'$  é uma matriz  $p \times n$  com o novo conjunto de dados utilizados para classificação.

Semelhante ao que foi apresentado nas classificações anteriores, a Tabela 7.5 mostra os resultados obtidos das classificações das sete classes de sinais, considerando o grupo A como grupo de treinamento da rede neural. Na Tabela 7.6 são apresentados os resultados das classificações quando da utilização do grupo B para treinamento da rede neural. Na seqüência, as Tabelas 7.7 e 7.8 apresentam os resultados das classificações utilizando os grupos C e D, respectivamente, para treinamento da rede neural. Os percentuais de acertos obtidos nas classificações com a utilização da ACP para cada conjunto de treinamento foram: 91,20%, 89,18%, 91,63% e 93,36%, para os grupos de treinos A, B, C e D, respectivamente.

Tabela 7.5 – Resultados das classificações com a ACP e utilizando o grupo A para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	5	<b>91</b>	1	0	0	2	0
<i>Flicker</i>	5	2	<b>88</b>	0	0	2	2
Harmônicos	0	0	0	<b>98</b>	0	1	0
Interrupção de tensão	0	0	2	0	<b>87</b>	0	10
<i>Notching</i>	3	1	4	0	1	<b>90</b>	0
Afundamento de tensão	0	0	0	0	12	8	<b>79</b>
Resolução da classificação: <b>91,20%</b>							

Tabela 7.6 – Resultados das classificações com a ACP e utilizando o grupo B para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	1	<b>97</b>	0	0	0	0	1
<i>Flicker</i>	5	4	<b>85</b>	0	0	4	1
Harmônicos	0	0	0	<b>97</b>	1	1	0
Interrupção de tensão	0	1	0	1	<b>72</b>	4	21
<i>Notching</i>	1	0	4	0	0	<b>94</b>	0
Afundamento de tensão	1	1	2	0	11	10	<b>74</b>
Resolução da classificação: <b>89,18%</b>							

Tabela 7.7 – Resultados das classificações com a ACP e utilizando o grupo C para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	3	<b>94</b>	1	0	0	1	0
<i>Flicker</i>	10	6	<b>75</b>	0	0	5	3
Harmônicos	0	0	0	<b>97</b>	0	0	2
Interrupção de tensão	0	0	0	0	<b>93</b>	0	6
<i>Notching</i>	6	1	0	0	0	<b>91</b>	1
Afundamento de tensão	3	0	0	0	10	0	<b>86</b>
Resolução da classificação: <b>91,63%</b>							

Tabela 7.8 – Resultados das classificações com a ACP e utilizando o grupo D para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Senóide pura	<b>99</b>	0	0	0	0	0	0
Transitório oscilatório	0	<b>94</b>	1	0	0	4	0
<i>Flicker</i>	3	2	<b>90</b>	0	0	3	1
Harmônicos	0	0	0	<b>99</b>	0	0	0
Interrupção de tensão	0	0	0	0	<b>92</b>	0	7
<i>Notching</i>	6	0	0	0	0	<b>92</b>	1
Afundamento de tensão	2	0	0	1	13	2	<b>81</b>
Resolução da classificação: <b>93,36%</b>							

### 7.1.3 Comparações das classificações

A Tabela 7.9 apresenta, de forma resumida, os percentuais de acertos obtidos em ambas as situações de classificação bem como os respectivos tempos de processamento para a execução dessas classificações. Nesta tabela é possível observar que o tempo para a execução de uma classificação é menor quando utilizado o algoritmo de análise de componentes principais. Embora ACP implique em mais uma rotina no processo de classificação, o tempo médio de classificação reduziu aproximadamente 16,84% em relação ao tempo gasto para a classificação sem a ACP, enquanto que a resolução média de classificação diminuiu apenas 2%. Isto ocorreu devido a uma redução de 70% no número de variáveis inseridas nas redes neurais. Tal redução também colaborou para a redução dos tempos de treinamento das RNPs, com exceção do treinamento com o grupo D, como mostra a Tabela 7.10.

Pode-se observar que o percentual de resolução mais elevado obtido com a ACP foi de 93,36%, Tabela 7.8, e de 94,23%, Tabela 7.4, sem a ACP. Ambos os resultados foram obtidos utilizando-se o grupo D para treinamento da rede neural. Isto mostra que o grupo D possui uma maior variabilidade nos seus dados amostrados, ou seja, as amostras de sinais contendo

Tabela 7.9 – Tempos e resoluções das classificações dos diferentes grupos.

Classificação:		Com ACP		Sem ACP	
Rede	Grupo	Tempo (ms)	Resolução (%)	Tempo (ms)	Resolução (%)
A	B	42,9	92,51	46,3	92,64
	C	42,1	94,37	47,0	95,24
	D	41,5	85,71	48,0	88,31
	<b>Médias:</b>	<b>42,21</b>	<b>91,20</b>	<b>47,1</b>	<b>92,06</b>
B	A	39,4	92,21	51,0	96,97
	C	39,9	91,77	48,5	95,67
	D	39,5	83,55	50,3	89,61
	<b>Médias:</b>	<b>39,6</b>	<b>89,18</b>	<b>49,9</b>	<b>94,08</b>
C	A	39,0	93,51	47,6	95,67
	B	40,1	91,77	48,7	92,21
	D	40,5	89,61	50,5	91,34
	<b>Médias:</b>	<b>39,9</b>	<b>91,63</b>	<b>48,9</b>	<b>93,07</b>
D	A	41,2	93,51	48,5	95,24
	B	40,3	92,21	47,6	91,34
	C	39,3	94,37	47,9	96,10
	<b>Médias:</b>	<b>40,3</b>	<b>93,36</b>	<b>48,0</b>	<b>94,23</b>
<b>Médias Gerais:</b>		<b>40,5</b>	<b>91,34</b>	<b>48,7</b>	<b>93,36</b>

Tabela 7.10 – Tempos de processamento para treinamento das redes neurais.

Grupo de Treino	Sem ACP	Com ACP
A	58,4 ms	55,8 ms
B	57,7 ms	57,0 ms
C	58,5 ms	56,3 ms
D	58,3 ms	58,4 ms

os fenômenos de QEE pertencentes a este grupo cobrem uma parte maior do espaço que caracteriza cada um dos distúrbios. De acordo com a Tabela 7.9, este grupo apresentou baixas taxas de classificação quando foi usado como grupo de teste e, por outro lado, quando usado como grupo de treino, as melhores taxas de classificações foram alcançadas.

## 7.2 Caracterização e reconhecimento de eventos que ocorrem na tensão medida no ponto onde um sistema de geração distribuída se conecta a uma rede de distribuição

Nesta parte da dissertação, o objetivo será analisar, por meio da TW, os efeitos que a conexão de um sistema de geração distribuída (GD) causa sobre a tensão medida no ponto de acoplamento comum (PAC) de um alimentador.

7.2.1 Descrição do sistema analisado

A Figura 7.3 mostra um diagrama unifilar do sistema utilizado para investigar o cenário típico de um sistema de GD conectado a um alimentador específico.

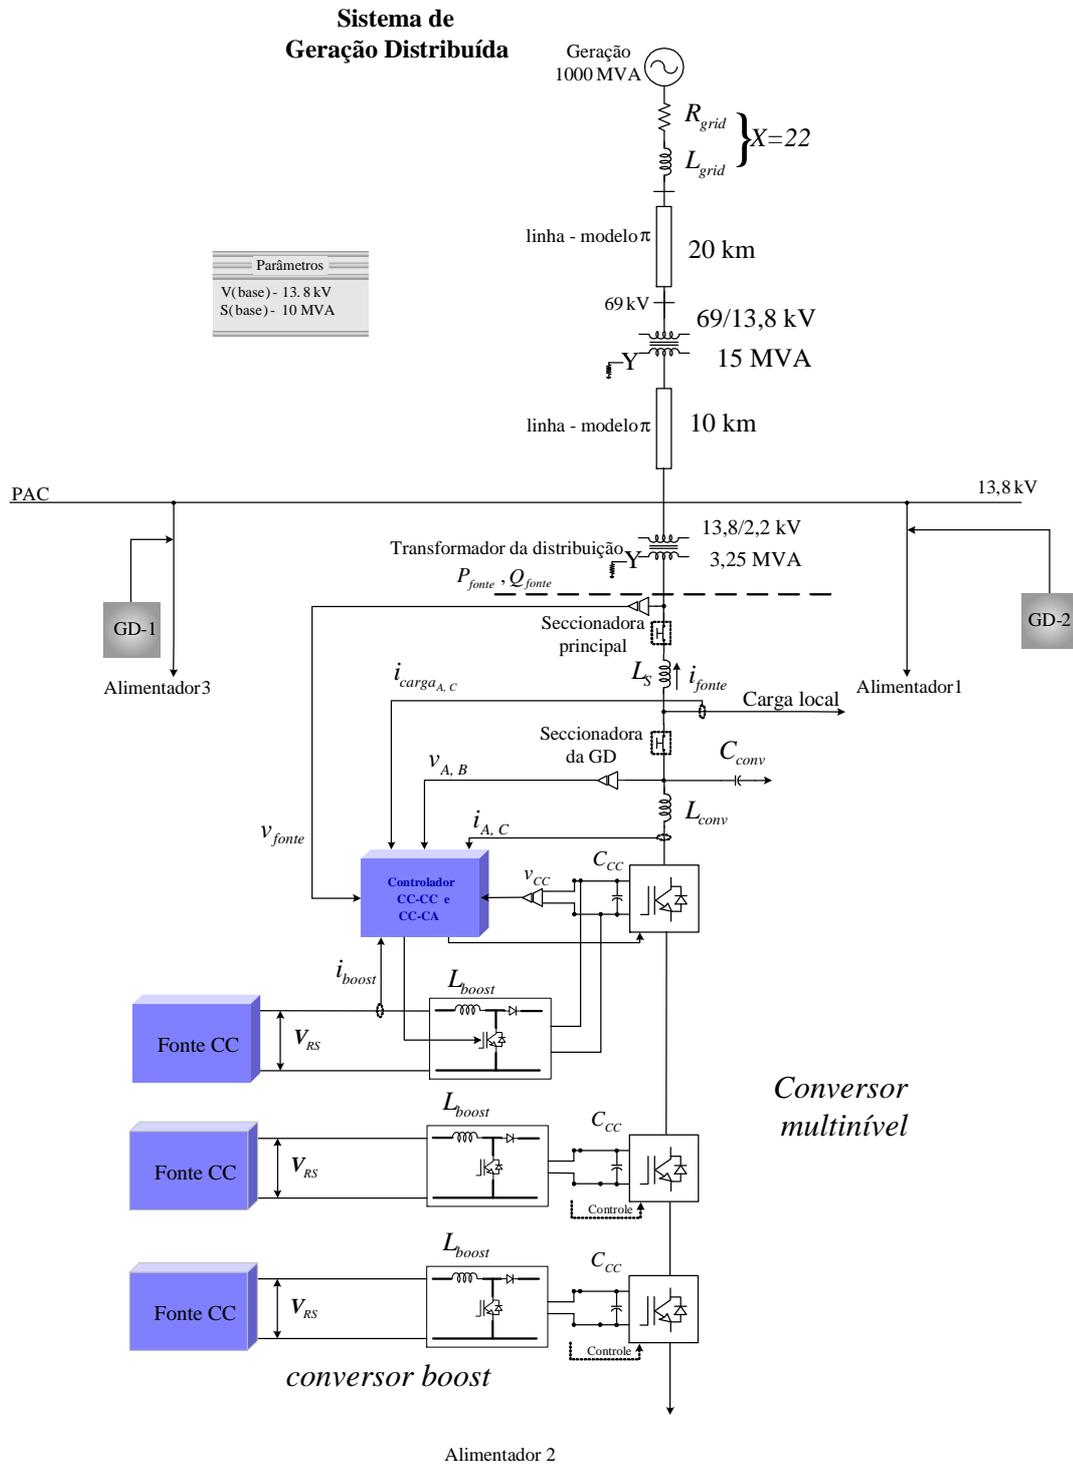


Figura 7.3 – Sistema de geração distribuída simulado no software PSCAD.

A configuração básica do sistema e os parâmetros são partes de um alimentador que pertence a uma distribuidora de energia. O sistema é composto por um alimentador de 13,8 kV conectado através de uma linha radial de 69 kV. O barramento de 13,8 kV da subestação é conectado a rede principal por um transformador da subestação e uma linha de 69 kV. A rede é representada pela sua capacidade de curto-circuito, conseqüentemente quanto mais alta a potência de curto-circuito, menos o sistema é susceptível a perturbações rápidas. Os parâmetros da rede são definidos pelas equações 7.1 e 7.2.

$$L_{grid} = \frac{V_{AB_{rms}}^2}{2\pi P_{SC} f} \quad (7.1)$$

$$R_{grid} = \frac{(2\pi f)L_{grid}}{X}, \quad 1 < X < 100, \quad (7.2)$$

onde  $L_{grid}$  e  $R_{grid}$  são respectivamente a indutância e a resistência da rede,  $P_{SC}$  é a potência de curto-circuito média do alimentador,  $f$  é a frequência (60 Hz),  $V_{AB_{rms}}$  é a tensão eficaz de linha produzida pelo conversor CC-CA, e  $X$  é a razão entre  $X_{L_{grid}}$  e  $R_{grid}$ .

O sistema de GD é composto por uma planta de 1 MVA que representa uma fonte secundária. Fontes renováveis de energia como célula de combustível e painéis fotovoltaicos podem ser utilizados como fontes de energia primária de um sistema de GD, bem como alguns tipos de sistemas armazenadores de energia como as baterias. Na Figura 7.3 as fontes de energia primária estão representadas pelas fontes de corrente contínua. Um conversor CC-CC é empregado para regular a tensão no barramento CC, e um conversor CC-CA multinível é empregado para garantir a qualidade da energia entregue aos consumidores, carga local e o alimentador, como mostrado na Figura 7.3.

No controle do fluxo de potência da GD para o alimentador foi utilizado um algoritmo que controla amplitude da tensão e o deslocamento de fase entre a tensão produzida pelo conversor e a tensão imposta pelo alimentador. Mais detalhes sobre este procedimento pode ser encontrado em (POZZATI et al., 2008).

Devido à baixa tensão produzida por este sistema de GD, um transformador de distribuição de 13,8 kV/2,2 kV foi utilizado para igualar os níveis de tensão da GD com a tensão fixada pelo sistema de distribuição (13,8 kV). Além disso, algumas chaves foram inseridas entre as GDs e o sistema de distribuição para isolar um do outro, evitando que as GDs entrem em colapso quando uma condição de contingência é detectada pelo algoritmo de detecção de ilhamento.

### 7.2.2 Simulações do sistema de geração distribuída

As simulações do sistema apresentado na Figura 7.3 foram executadas no ambiente PSCAD. No MATLAB, os sinais de tensão obtidos das diversas simulações são empregados para reconhecer as seguintes situações: (1) conexão do sistema de GD a rede de distribuição, (2) conexão de carga local, (3) operação normal e (4) operação quando o sistema está ilhado. De forma similar ao caso anterior, os sinais foram analisados pela TW e decompostos em 9 níveis de resolução.

A Figura 7.4 mostra o sinal de tensão no PAC (ponto de acoplamento comum), de 0 a 1,6 segundos, e os seus coeficientes de detalhes para 3 níveis de decomposição da AMR, representados por d1, d3 e d4, que equivalem ao primeiro, terceiro e quarto níveis, respectivamente. Como se pode observar, a Figura 7.4 representa a primeira situação, na qual o sistema de GD foi conectado ao alimentador após a sincronização ter sido estabelecida, em aproximadamente 120 ms. Este evento é claramente identificado já no primeiro nível de detalhes (d1) da TW.

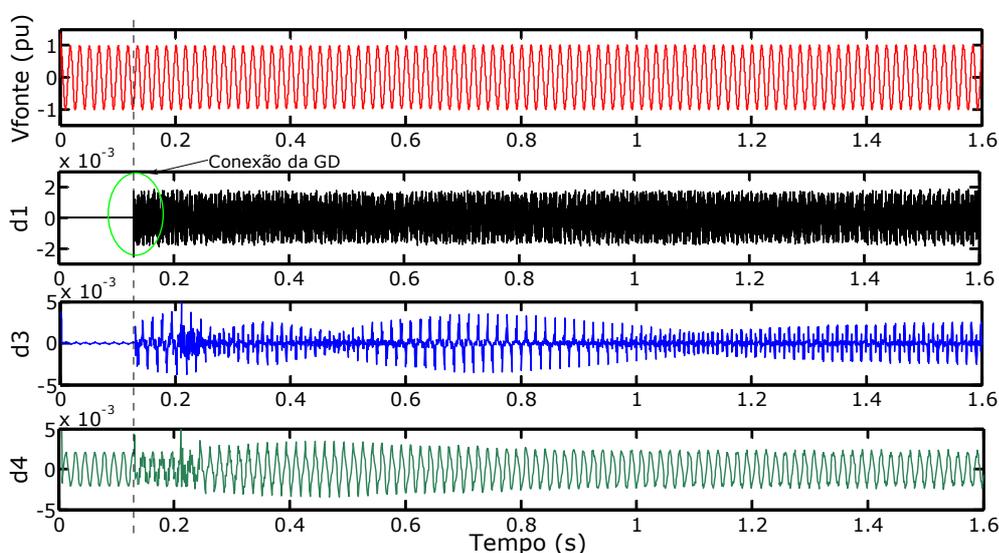


Figura 7.4 – Sinal de tensão e coeficientes de detalhes no momento da conexão da GD.

A Figura 7.5 representa a segunda situação que ocorreu entre 1,6 e 4,5 segundos das simulações, onde a GD estava operando conectada a rede e uma carga local foi inserida em 2,5 segundos. Neste caso, a conexão causou mais efeitos nos coeficientes de detalhes d3 e d4 do que nos coeficientes d1, mostrados na Figura 7.5. É relevante salientar que estas alterações nos coeficientes de detalhes podem variar dependendo do tipo de carga que é conectada no sistema.

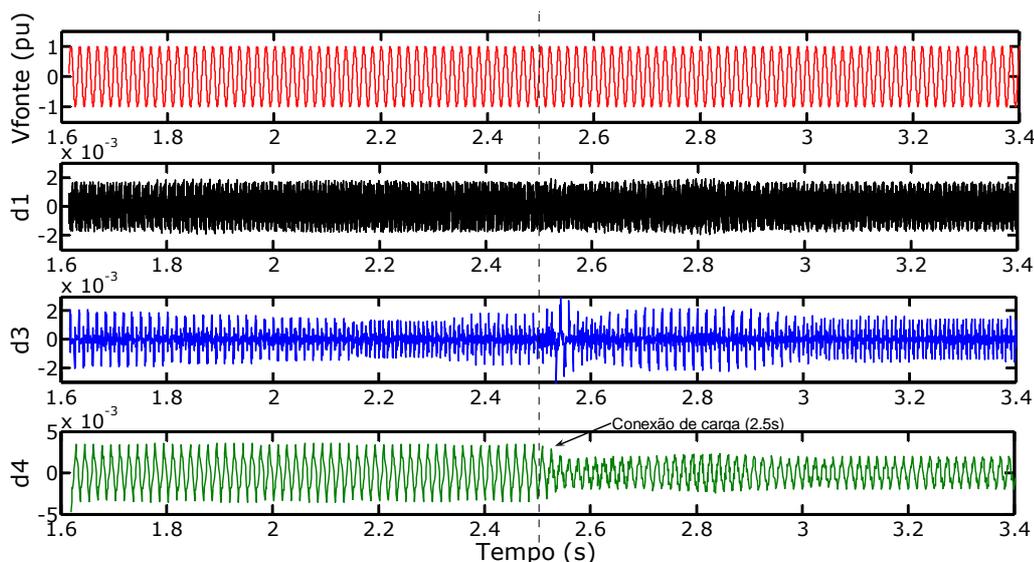


Figura 7.5 – Sinal de tensão e coeficientes de detalhes no instante em que uma carga local foi conectada.

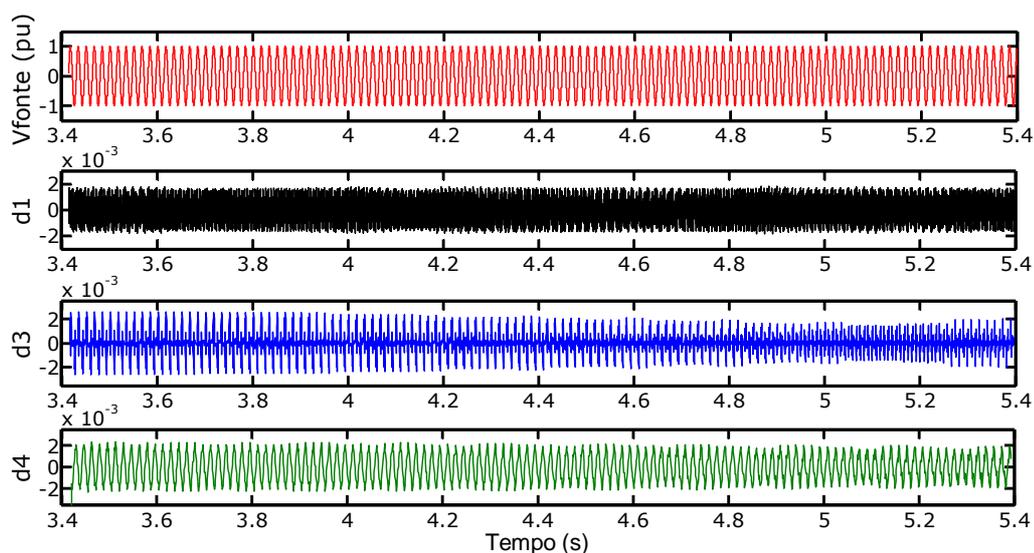


Figura 7.6 – Sinal de tensão e coeficientes de detalhes quando o sistema de GD e rede operam normalmente.

Na Figura 7.6 não ocorrem variações nem no sinal de tensão nem nos coeficientes de detalhes, pois não houve nenhuma mudança no sistema. Já na Figura 7.7, entre 5,4 e 7 segundos, o sistema de GD começou a operar de modo ilhado. Este fenômeno pode ser entendido como um curto-circuito seguido pela ativação dos dispositivos de proteção no lado de alta tensão do transformador de distribuição, que conecta a GD ao alimentador.

Quando ocorre um ilhamento, este é detectado e seu gerenciamento é feito pelo algoritmo de detecção de ilhamento que faz o sistema rede e GD operarem em condições anormais. Este efeito de operação é claramente observado nos primeiros coeficientes de detalhes da AMR, onde ocorrem consideráveis aumentos nas amplitudes dos coeficientes,

como mostra a Figura 7.7. Estas variações nos coeficientes ocorrem porque a DHT (distorção harmônica total) no lado de baixa tensão do transformador de distribuição muda após ocorrer o ilhamento.

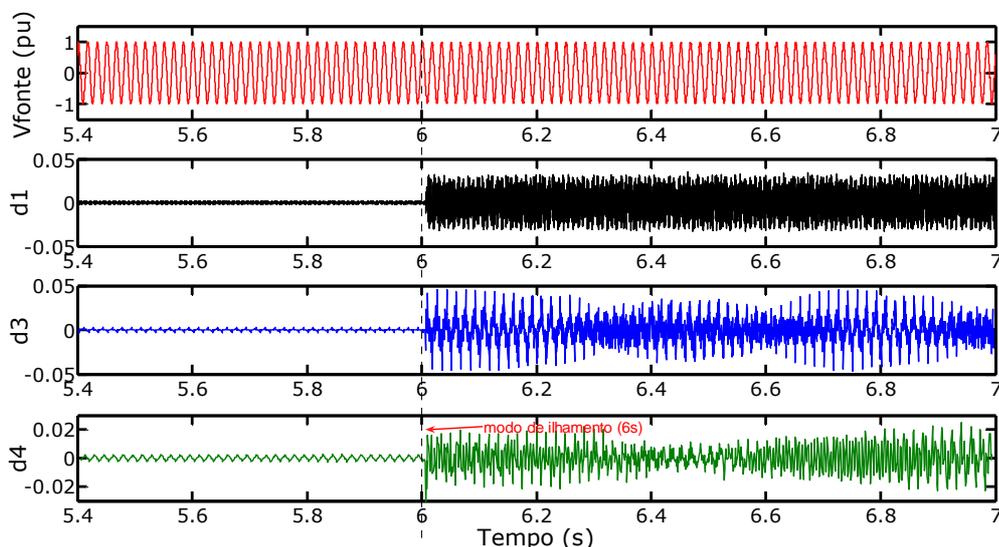


Figura 7.7 – Sinal de tensão e coeficientes de detalhes quando a GD começa a operar isolada da rede.

### 7.2.3 Classificações dos eventos

De forma a discriminar cada uma das quatro situações anteriores, as características extraídas dos sinais foram integradas aquelas do primeiro caso. As redes neurais foram treinadas novamente para reconhecerem mais quatro padrões. Foi utilizado o mesmo procedimento de classificação realizado na seção 7.1.2, ou seja, as classificações foram realizadas utilizando o algoritmo de ACP, que é a proposta dessa dissertação. Neste caso não foram realizadas classificações sem a utilização da ACP.

Devido ao longo período de tempo requerido para a realização das simulações do sistema representado na Figura 7.3, foram considerados apenas 3 grupos de sinais, e não 4 como no caso anterior. Ao todo foram realizadas 12 simulações do sistema GD/alimentador, 4 simulações para cada grupo, e o sinal de tensão de cada uma dessas simulações foi dividido em 4 situações observadas na tensão medida no PAC do sistema. Assim, além das 7 classes, foram incluídas mais 4, que são as seguintes:

$D_8 \rightarrow$  Conexão da GD ao alimentador.

$D_9 \rightarrow$  Conexão de diferentes cargas locais como motores de indução, cargas não-lineares e cargas resistivas.

D<sub>10</sub> → Operação normal.

D<sub>11</sub> → Operação quando o sistema está ilhado.

A análise de componentes principais foi realizada para cada um dos três grupos de treinamento A2, B2 e C2. As contribuições com relação à variância dos dados representadas por essas componentes estão representadas na Figura 7.8. Os resultados de classificação dos três grupos, A2, B2 e C2, são apresentados nas Tabelas 7.11 a 7.13.

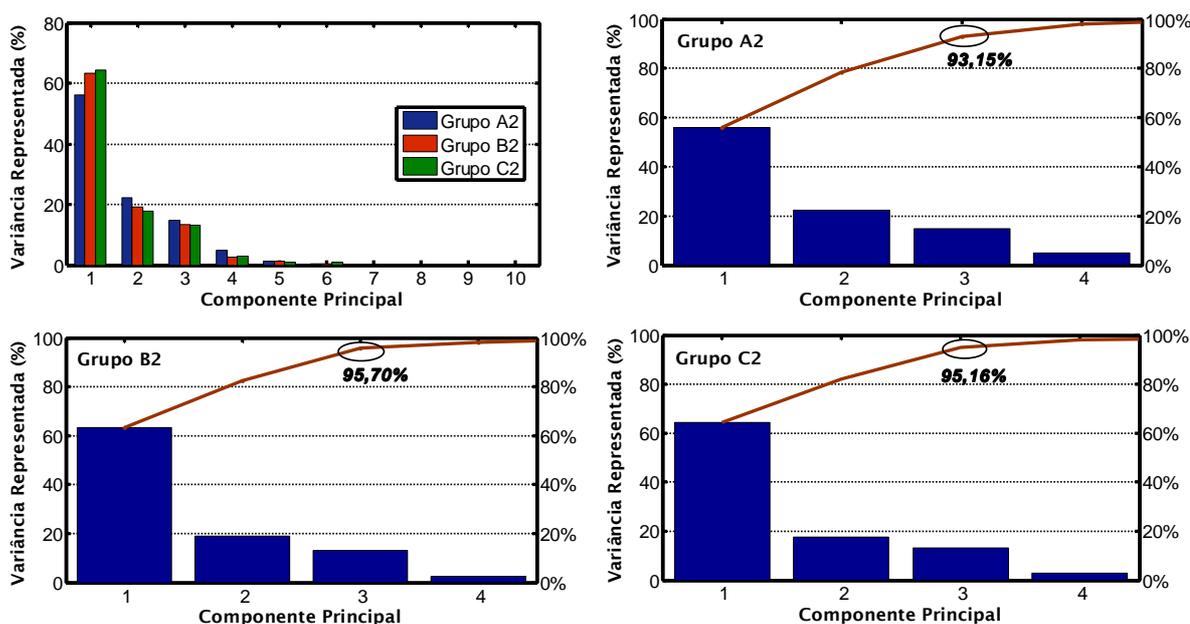


Figura 7.8 – Variâncias representadas pelas componentes principais e variâncias acumuladas pelas 3 primeiras componentes em cada um dos grupos.

Tabela 7.11 – Resultados das classificações com a ACP utilizando o grupo A2 para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>	D <sub>8</sub>	D <sub>9</sub>	D <sub>10</sub>	D <sub>11</sub>
Senóide pura	<b>66</b>	0	0	0	0	0	0	0	0	0	0
Transitório oscilatório	0	<b>65</b>	0	0	0	1	0	0	0	0	0
Flicker	7	2	<b>53</b>	0	0	3	1	0	0	0	0
Harmônicos	0	0	0	<b>64</b>	0	1	1	0	0	0	0
Interrupção de tensão	0	0	2	0	<b>45</b>	3	16	0	0	0	0
Notching	0	4	2	0	0	<b>60</b>	0	0	0	0	0
Afundamento de tensão	0	0	1	0	9	10	<b>46</b>	0	0	0	0
Conexão da GD	0	0	0	0	0	0	0	<b>8</b>	0	0	0
Conexão de cargas	0	0	0	0	0	0	0	0	<b>8</b>	0	0
Operação normal	0	0	0	0	0	0	0	0	0	<b>8</b>	0
Ilhamento	5	0	0	0	0	0	0	1	0	0	<b>2</b>

Resolução da classificação: **86,03%**

Tabela 7.12 – Resultados das classificações com a ACP utilizando o grupo B2 para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>	D <sub>8</sub>	D <sub>9</sub>	D <sub>10</sub>	D <sub>11</sub>
Senóide pura	<b>66</b>	0	0	0	0	0	0	0	0	0	0
Transitório oscilatório	2	<b>61</b>	1	0	0	2	0	0	0	0	0
<i>Flicker</i>	9	4	<b>50</b>	0	0	3	0	0	0	0	0
Harmônicos	0	0	0	<b>64</b>	0	0	2	0	0	0	0
Interrupção de tensão	0	0	0	0	<b>57</b>	0	9	0	0	0	0
<i>Notching</i>	4	3	0	0	0	<b>59</b>	0	0	0	0	0
Afundamento de tensão	1	0	0	0	8	1	<b>56</b>	0	0	0	0
Conexão da GD	0	0	0	0	0	0	0	<b>8</b>	0	0	0
Conexão de cargas	0	0	0	0	0	0	0	0	<b>8</b>	0	0
Operação normal	0	0	0	0	0	0	0	0	0	<b>8</b>	0
Ilhamento	3	0	0	0	0	0	0	1	0	0	<b>4</b>
Resolução da classificação: <b>89,27%</b>											

Tabela 7.13 – Resultados das classificações com a ACP utilizando o grupo C2 para treinamento.

	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>	D <sub>8</sub>	D <sub>9</sub>	D <sub>10</sub>	D <sub>11</sub>
Senóide pura	<b>66</b>	0	0	0	0	0	0	0	0	0	0
Transitório oscilatório	0	<b>61</b>	1	0	0	4	0	0	0	0	0
<i>Flicker</i>	7	1	<b>55</b>	0	0	2	1	0	0	0	0
Harmônicos	0	0	0	<b>66</b>	0	0	0	0	0	0	0
Interrupção de tensão	0	0	0	0	<b>58</b>	0	8	0	0	0	0
<i>Notching</i>	4	0	0	0	0	<b>61</b>	1	0	0	0	0
Afundamento de tensão	1	0	0	1	14	2	<b>48</b>	0	0	0	0
Conexão da GD	0	0	0	0	0	0	0	<b>8</b>	0	0	0
Conexão de cargas	0	0	0	0	0	0	0	0	<b>8</b>	0	0
Operação normal	0	0	0	0	0	0	0	0	4	<b>4</b>	0
Ilhamento	2	0	0	0	0	0	0	2	0	0	<b>4</b>
Resolução da classificação: <b>88,87%</b>											

As três tabelas anteriores mostram as classificações de sinais pertencentes a onze classes de distúrbios, sendo as sete primeiras representando distúrbios clássicos relacionados à QEE e as quatro últimas um caso particular de fenômenos possíveis de ocorrer em sistemas de GD. Observando os resultados das tabelas, percebe-se o percentual de classificação apresentado pelo algoritmo considerando as onze classes. Também é possível verificar que a inclusão de mais quatro padrões para a classificação não interferiu significativamente nas classificações das sete primeiras classes. Isto mostra a relevância das características extraídas e o potencial das redes neurais em reconhecer padrões.

Observando nas Tabelas 7.11 a 7.13 somente as classificações das quatro últimas classes, constata-se que o algoritmo classificou corretamente todas as situações em que ocorreu a conexão da GD e também todas as situações nas quais foram conectadas cargas ao

sistema em análise. Uma menor identificação ocorreu com os casos de ilhamento, mesmo assim em duas das três classificações ocorreu o reconhecimento de 50% dessas situações. Já na observação dos detalhes obtidos através da TW, este fenômeno é bem caracterizado e talvez possa ser identificado de alguma outra forma, mas aplicando a TW. Um fator que pode ter interferido nestas classificações é a menor quantidade de amostras utilizadas, pois foram utilizadas neste caso somente quatro de cada vez para treinamento da rede neural.

### **7.3 Considerações finais**

Neste capítulo foram apresentadas as classificações de distúrbios relacionados à qualidade da energia elétrica. Um algoritmo, que utiliza a TW e redes neurais, foi aplicado para extrair características e classificar sinais com distúrbios. A análise de componentes principais foi empregada para reduzir a dimensão do espaço de características dos distúrbios, o que permitiu realizar as classificações com redução do tempo de processamento.

Uma análise e classificação de sinais medidos no PAC de um sistema de GD conectado a um alimentador foram realizadas através do mesmo algoritmo, com o intuito de reconhecer perturbações ou eventos que comumente ocorrem quando sistemas de GD operam conectados a redes de distribuição. Ao final pode-se verificar o alto potencial da combinação da transformada *wavelet*, análise de componentes principais e redes neurais em QEE.

## 8 CONCLUSÕES E TRABALHOS FUTUROS

No decorrer do trabalho foi visto que os problemas na qualidade da energia elétrica englobam uma extensa gama de diferentes fenômenos. Cada um desses fenômenos pode ter diferentes causas e também diferentes soluções que podem ser utilizadas para melhorar a qualidade da energia elétrica e a performance de equipamentos. Por isso, a motivação de se estudar métodos que possibilitem uma identificação eficaz de cada um dos fenômenos.

Também foi mostrado que a transformada *wavelet* provê informações sobre o conteúdo de frequência de sinais similarmente a transformada de *Fourier* (TF). Porém, ao contrário da TF, a TW é capaz de focalizar pequenos intervalos de tempo para conteúdos de alta frequência e em longos intervalos de tempo para conteúdos de baixa frequência. Por este motivo ela se tornou uma desejável ferramenta para a análise de fenômenos relacionados à qualidade da energia, principalmente quando são tratados transitórios de alta frequência como impulsos e oscilações localizadas, nos quais se tem a presença da componente fundamental.

Com os estudos da análise de componentes principais, foi possível concluir que esta ferramenta pode ser utilizada como uma forma de identificar padrões em dados correlacionados e expressar esses dados de forma que suas similaridades e diferenças sejam destacadas. Isto é feito com a criação de novos conjuntos de dados, totalmente decorrelacionados, a partir dos dados originais. Através da análise de componentes principais é possível realizar uma compressão dos dados, ou seja, reduzir o número de dimensões, sem perda de informação.

Por fim, foi apresentada uma metodologia para a análise e classificação de diferentes distúrbios relacionados à QEE. Nesta metodologia foram analisados pela TW a fim de se extrair características no domínio do tempo e frequência e se obter uma boa discriminação entre os distúrbios. Estas características foram medidas pelas curvas de desvio padrão e média das componentes obtidas da AMR. Com o intuito de reduzir ainda mais a quantidade de dados e o tempo requerido para a classificação dos distúrbios, propôs-se aplicar a análise de componentes principais para decorrelacionar variáveis contidas nos vetores de características e, então, escolher as mais significativas para realizar a classificação.

Para a etapa de classificação optou-se por um método de reconhecimento de padrões através de redes neurais artificiais, mais especificamente, uma rede neural probabilística que tem como saída o tipo de distúrbio contido nos sinais analisados. A análise de componentes principais, que foi utilizada para reduzir a dimensão do espaço de características dos

distúrbios, permitiu realizar as classificações em tempos menores do que sem a utilização desta análise.

Neste trabalho, foram realizadas análises e classificações de sinais medidos no PAC de um sistema de GD conectado a um alimentador. Estas análises foram realizadas através do mesmo algoritmo, com o intuito de reconhecer perturbações ou eventos que comumente ocorrem quando sistemas de GD operam conectados a redes de distribuição. Através da análise gráfica foi possível identificar, nos coeficientes de detalhes da transformada wavelet, as variações e perturbações no sinal de tensão no PAC quando da ocorrência de um dos fenômenos considerados e também, as informações, no tempo, de tais ocorrências.

Ao final pode-se verificar o alto potencial da combinação da transformada *wavelet*, análise de componentes principais e redes neurais na identificação de fenômenos relacionados à qualidade da energia elétrica. Desta forma, acredita-se que o objetivo desta dissertação de mestrado foi alcançado, uma vez que a proposta inicial era a construção de um algoritmo que classificasse alguns fenômenos que deterioram a qualidade da energia elétrica com redução na quantidade de dados e nos tempos de processamento.

Com os resultados satisfatórios deste trabalho, pretende-se continuar pesquisas com a utilização da transformada *wavelet* em sinais elétricos, na análise de sistemas de geração distribuída, na tentativa de identificar mais precisamente fenômenos como o ilhamento.

Um outro ponto interessante seria realizar análises não só em sinais de tensão, mas também em sinais de potência, na tentativa de identificar oscilações que ocorrem nas mesmas. Como a TW separa o sinal em bandas de frequências, pode ser possível compensar as variações na corrente e/ou tensão utilizando-a como filtros de bandas. Para tais situações há a possibilidade de se construir um algoritmo não mais de simulação, mas que opere em situações experimentais utilizando um processador digital de sinais (DSP - *digital signal processor*).

## REFERÊNCIAS BIBLIOGRÁFICAS

ABDEL-GALIL, T. K. et al. Disturbance Classification Using Hidden Markov Models and Vector Quantization. *IEEE Transactions on Power Delivery*, vol. 20, n. 3, p. 2129 – 2135, jul. 2004.

ANEEL. Agência Nacional de Energia Elétrica: Resolução N° 024, p.15, jan., 2000.

ANEEL. Agência Nacional de Energia Elétrica: Resolução N° 505, p.15, nov., 2001.

ARRUDA, E. F. Análise de Distúrbios Relacionados com a Qualidade da Energia Elétrica Utilizando a Transformada Wavelet. Dissertação de mestrado. São Carlos, 2003.

BOLLEN, M. H. J. Understand Power Quality Problems: voltage sags and interruptions. New York: IEEE Press, xvii, 543 p., 1999.

CASTELLS, F. et al. Principal component analysis in ECG signal processing, *EURASIP Journal on Advances in Signal Processing*, vol. 2007, 21 p., 2007.

CHEN, S.; ZHU, H. Y. Wavelet Transform for Processing Power Quality Disturbances. *EURASIP Journal on Advances in Signal Processing*, vol. 2007, 20 pages, 2007.

CHUNG, J. et al. Electric Power Transient Disturbance Classification Using Wavelet-Based Hidden Markov Models. *Processing, IEEE International Conference on Acoustics, Speech, and Signal*, vol.6, p. 3662 – 3665, 2000.

CHUNG, J. et al. Power Disturbance Classifier Using Rule-Based Method and Wavelet Packet-Based Hidden Markov Model. *IEEE Transactions on Power Delivery*, vol. 17, n. 1, p. 233 – 241, jan. 2002.

DAUBECHIES, I. Ten Lectures on Wavelets. Philadelphia, Pa.: Society for Industrial and Applied Mathematics (SIAM). xix, 357 p., 1992.

DAUBECHIES, I. Where Wavelets Come From? – A Personal Point of View. *Proceedings of the IEEE*, Vol. 84, No.4, p. 510-513, Apr. 1996.

DEBNATH, L. Wavelet Transforms and Their Applications. Birkhäuser: Boston, 575 p., 2002.

DELMONT, O. F. Um Algoritmo para Detecção, Localização e Classificação de Distúrbios na Qualidade da Energia Elétrica Utilizando a Transformada *Wavelet*. Tese de Doutorado, Escola de Engenharia de São Carlos – EESC/USP, 209 p., São Carlos, 2007.

DELMONT, O. F. Utilização da Transformada *Wavelet* para Caracterização de Distúrbios na Qualidade da Energia Elétrica. Dissertação de mestrado, Escola de Engenharia de São Carlos – EESC/USP, 103 p., São Carlos, 2003.

DUGAN, R. C. et al. *Electrical Power Systems Quality*, 2<sup>nd</sup> ed., Ed. McGraw-Hill, 528 p., 2002.

GAING, Z.-L. Wavelet-Based Neural Network for Power Disturbance Recognition and Classification. IEEE Transactions on Power Delivery, vol. 19, n. 4, p. 1560 – 1568, out. 2004.

IEEE Recommended Practice for Monitoring Electric Power Quality (IEEE Std 1159-1995). IEEE, p.76, jun., 1995.

IEEE Recommended Practices and Requirements for Harmonic Control in Electrical Power Systems (IEEE Std 519-1992). IEEE, p.101, abr., 1993.

JOLLIFFE, I. T. Principal Component Analysis, New York, NY, USA, 487 p., 2002.

KANITPANYACHAROEAN, W.; PREMRUDEEPPREECHACHARN, S. Power Quality Problem Classification Using Wavelet Transform and Artificial Neural Networks. IEEE PES Power Systems Conference and Exposition, vol. 13, p. 1946 – 1501, 2004.

KARIMI, M.; MOKHTARI, H.; IRAVANI, M. R. Wavelet Based On-Line Disturbance Detection for Power Quality Applications. IEEE Transactions on Power Delivery, vol. 15, n.4, p. 1212 – 1220, out. 2000.

LAURENE, F. Fundamentals of Neural Networks Architectures, Algorithms and Applications”, Prentice Hall, 1994.

LIMA, P. C. Wavelets: Teoria, Algoritmos e Aplicações. Belo Horizonte: Departamento de Matemática – ICEX – UFMG, 2003.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation, IEEE Trans. Pattern Analysis and Machine intelligence, vol. 11, no. 7, pp. 674 – 693, 1989.

MISITI, M. et al. Wavelet Toolbox 4: User’s Guide. Natick, MA: The Math Works, 1202 p., 2008.

MOKHTARI, H.; KARIMI, M.; IRAVANI, M. R. Experimental Performance Evaluation of a Wavelet-Based On-Line Voltage Detection Method for Power Quality Applications. IEEE Transactions on Power Delivery, vol. 17, n. 1, p. 161 – 172, jan. 2002.

OLESKOVICZ, M. et al. Estudo Comparativo de Ferramentas Modernas de Análise Aplicadas à Qualidade da Energia Elétrica. Revista Controle & Automação, vol. 17, n. 3, p. 331 – 341, jul-set 2006.

OLESKOVICZ, M. Qualidade da Energia – Fundamentos Básicos. Escola de Engenharia de São Carlos – EESC/USP, Departamento de Engenharia Elétrica, São Carlos, 2004.

OLIVEIRA, H. M. Análise de Sinais para Engenheiros: Uma abordagem via Wavelets. Rio de Janeiro: ed. Brasport, 244 p., 2007.

POZZATI, L. F et al. Renewable Energy Supplies Driven by DC-DC and DC-AC High Power Converters Connected to the Distribution System, Electric Power Systems Research, aceito para publicação, 2008.

POZZEBON, G. G. et al. Neural Classification of Power Quality Disturbances Using Wavelet Transform and Principal Component Analysis. In: VIII Conferência Internacional de Aplicações Industriais - Induscon, 2008, Poços de Caldas, MG, v. único, 2008.

POZZEBON, G. G. et al. Principal Component Analysis in Power Quality Disturbance Classifier Using Wavelet Transform and Neural Network. In: XVII Congresso Brasileiro de Automática - CBA 2008, Juiz de Fora, MG, v. único, 2008.

SANTOSO, S. et al. Power Quality Assessment Via Wavelet Transform Analysis. IEEE Transactions on Power Delivery, vol. 11, n. 2, p. 924 – 930, abr. 1996.

SANTOSO, S. et al. Power Quality Disturbance Waveform Recognition Using Wavelet-Based Neural Classifier – Part 1: Theoretical Foundation. IEEE Transactions on Power Delivery, vol. 15, n. 1, p. 222-228, jan. 2000.

SANTOSO, S. et al. Power Quality Disturbance Waveform Recognition Using Wavelet-Based Neural Classifier – Part 1: Application. IEEE Transactions on Power Delivery, vol. 15, n. 1, p. 229-235, jan. 2000.

SANTOSO, S.; POWERS, E.J.; GRADY, W.M. Electric Power Quality Disturbance Detection Using Wavelet Transform analysis. Proceedings of the IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis. Philadelphia, PA, USA, p. 166 – 169, out. 1994.

SHLENS, J. A Tutorial on Principal Component Analysis, Institute for Nonlinear Science, University of Califórnia, San Diego, 2005.

SPECHT, D. F. Probabilistic neural networks, Neural Networks, vol.3, no. 1, pp. 109 – 118, 1990.

STRANG, G.; NGUYEN, T. Wavelets and Filter Banks. Wellesley-Cambridge Press, Wellesley, 490 p., 1996.

TOU, J. T.; GONZALEZ, R. C. Pattern Recognition Principles, Applied Mathematics and Computations, no. 07, 1974.

YANG, K., SHAN, G., ZHAO, L. Application of wavelet packet analysis and probabilistic neural networks in fault diagnosis. The 6<sup>th</sup> World Congress on Intelligent Control and Automation, vol. 1, pp. 4378 – 4381, 2006.

ZHU, T. X.; TSO, S. K.; LO, K. L. Wavelet-Based Fuzzy Reasoning Approach to Power-Quality Disturbance Recognition. IEEE Transactions on Power Delivery, vol. 19, n. 4, p. 1928-1934, out. 2004.